

UNIVERSIDAD AUTONOMA DE NUEVO LEON
FACULTAD DE INGENIERIA MECANICA Y ELECTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



**DISEÑO DE UN SISTEMA DE MONITOREO DE CONDUCCIÓN A NIVEL
PROTOTIPO, MEDIANTE TECNOLOGÍAS INNOVADORAS A UN BAJO COSTO**


Por:
JORGE LUIS NÚÑEZ GONZÁLEZ

EN OPCIÓN AL GRADO DE:
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA AUTOMOTRIZ

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

SEPTIEMBRE 2024

UNIVERSIDAD AUTONOMA DE NUEVO LEON
FACULTAD DE INGENIERIA MECANICA Y ELECTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



**DISEÑO DE UN SISTEMA DE MONITOREO DE CONDUCCIÓN A NIVEL
PROTOTIPO, MEDIANTE TECNOLOGÍAS INNOVADORAS A UN BAJO COSTO**

Por:
JORGE LUIS NÚÑEZ GONZÁLEZ

EN OPCIÓN AL GRADO DE:
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA AUTOMOTRIZ

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

SEPTIEMBRE 2024

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
Facultad de Ingeniería Mecánica y Eléctrica
Posgrado

Los miembros del Comité de Evaluación de Tesis recomendamos que la Tesis “Diseño de un Sistema de Monitoreo de Conducción a Nivel Prototipo mediante Tecnologías Innovadoras a un Bajo Costo”, realizada por el estudiante Jorge Luis Núñez González, con número de matrícula 2125663, sea aceptada para su defensa como requisito parcial para obtener el grado de Maestría en Ciencias de la Ingeniería Automotriz.

El Comité de Evaluación de Tesis

Dr. Héctor Gilberto Barrón González
Director

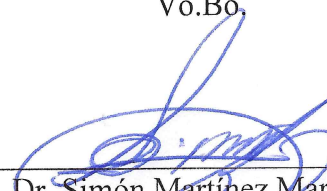

Dra. Adriana Salas Zamarripa
Co-director

Dra. Tania Paloma Berber Solano
Revisor

Dr. Diego Francisco Ledezma Ramírez
Revisor

Dr. Ricardo Ambrocio Ramírez Mendoza
Revisor

Vo.Bo.



Dr. Simón Martínez Martínez
Subdirector de Estudios de Posgrado

Institución 190001

Programa 554502

Acta Núm. 4137

Ciudad Universitaria, a 7 de noviembre 2024.

DECLARACIÓN DE AUTENTICIDAD

Declaro solemnemente que el documento que en seguida presento es fruto de mi propio trabajo y hasta donde estoy enterado no contiene material previamente publicado o escrito por otra persona, excepto aquellos materiales o ideas que por ser de otras personas les he dado el debido reconocimiento y los he citado debidamente en la bibliografía o referencias.

Declaro además que tampoco contiene material que haya sido aceptado para el otorgamiento de cualquier grado o diploma de alguna universidad o institución.

Nombre: Jorge Luis Núñez González

Firma: 

Fecha: a 15 de septiembre 2024

AGRADECIMIENTOS

A la Universidad Autónoma de Nuevo León por el apoyo brindado a través de mis profesores de la Facultad de Ingeniería Mecánica y Eléctrica.

En especial al Dr. Héctor Gilberto Barrón González por la asesoría en el presente trabajo de tesis que pongo a su disposición. Así como a la Dra. Adriana Salas Zamarripa, Coordinadora Académica de la MCIA por su invaluable apoyo.

ABREVIATURAS Y TÉRMINOS TÉCNICOS

ADAS: Advanced Driver Assistance Systems o Sistema Avanzado de Asistencia a la Conducción.

FCW: Forward Collision Warning System o Sistema de Advertencia de Colisión Frontal.

BDS: Blind Spot Detection System o Sistema de Detección de Puntos Ciego.

OEM: Original Equipment Manufacture, y hace referencia a un fabricante de equipamiento original.

NOM: Normas Oficiales Mexicanas.

LDW: Line Departure Warning System o Sistema de Advertencia de Cambio de Carril.

ML: Machine Learning o Aprendizaje Automático.

LKAS: Lane Keeping Assist System o Sistema de Mantenimiento de Carril.

AEB: Autonomous Emergency Breaking System o Sistema de Frenado Autónomo de Emergencia.

TABLA DE CONTENIDO

COMITÉ DE TESIS	iii
DECLARACIÓN DE AUTENTICIDAD	iv
AGRADECIMIENTOS	v
ABREVIATURAS Y TÉRMINOS TÉCNICOS	vi
TABLA DE CONTENIDO	vii
ÍNDICE DE ILUSTRACIONES	xii
ÍNDICE DE TABLAS	xiv
ÍNDICE DE ECUACIONES	xv
RESUMEN	xvi
I. INTRODUCCIÓN	1
1.1 Naturaleza y Dimensión del Estudio	1
1.1.1 <i>ADAS</i>	1
1.1.1.1 <i>Causas principales en los accidentes de tránsito</i>	1
1.1.1.2 <i>Costo socioeconómico de los accidentes viales</i>	2
1.1.1.3 <i>Tipos de siniestros viales con mayor riesgo</i>	3
1.1.1.4 <i>Contexto Nacional</i>	4
1.1.1.5 <i>Medidas adoptadas para reducir los accidentes viales en México</i>	5
1.1.2 <i>Antecedentes</i>	6
1.1.2.1 <i>Análisis crítico de la literatura</i>	6
1.1.3 <i>Metodología de la Investigación</i>	8
1.1.3.1 <i>Declaración del problema y propósito del estudio</i>	8
1.1.3.2 <i>Importancia y justificación del estudio</i>	8
1.1.3.3 <i>Hipótesis general de investigación</i>	9
1.1.3.4 <i>Objetivo general de la investigación</i>	10
1.1.3.5 <i>Objetivos específicos de la investigación</i>	10
II. MATERIALES Y METODOLOGÍA	13
2.1 Materiales	13
2.1.1 <i>Evaluación de materiales a utilizar</i>	13
2.1.2 <i>Ambientes utilizados para el desarrollo del sistema (Python y Open CV)</i>	14
2.1.2.1 <i>Open CV</i>	14
2.1.2.2 <i>Python-Pytorch</i>	14

2.2	Metodología.....	15
2.2.1	<i>Evaluación de los métodos de preparación para las pruebas</i>	15
2.2.1.1	<i>Condiciones iniciales del pavimento</i>	15
2.2.2	<i>Condiciones iniciales de los vehículos</i>	15
2.2.3	<i>Preparación de los vehículos</i>	16
2.2.4	<i>Características físicas de los vehículos</i>	16
2.3	Plan de implementación para las pruebas en campo.....	16
2.3.1	<i>Plan de implementación para la prueba BSD</i>	16
2.3.1.1	<i>Esquematización de la prueba en línea recta para BSD</i>	17
2.3.2	<i>Plan de implementación para la prueba FCW</i>	18
2.3.2.1	<i>Esquematización de la prueba en línea recta para FCW</i>	19
2.4	Desarrollo del sistema para la implementación.....	20
2.4.1	<i>Modelo utilizado para el análisis y procesamiento</i>	21
2.4.2	<i>Principio y arquitectura de YOLO v4</i>	21
2.4.2.1	<i>Arquitectura de YOLO v4</i>	23
2.4.2.2	<i>Funcionamiento del modelo YOLO v4 para la detección de objetos</i>	24
2.4.2.3	<i>Limitaciones de YOLOv4 en la detección de vehículos</i>	29
2.4.3	<i>Modelado del programa para la detección de vehículos en Python</i>	31
2.4.3.1	<i>Configuración del programa para la detección de vehículos en Python</i>	32
2.4.3.2	<i>Diagrama de flujo del programa desarrollado en Python</i>	36
2.4.3.3	<i>Interfaz de usuario e iniciación de cámaras en Python</i>	37
2.4.3.4	<i>Captación de video en tiempo real</i>	38
2.4.4	<i>Posicionamiento de las cámaras en el vehículo (pruebas de campo)</i>	39
2.4.4.1	<i>Cálculo de la distancia y longitud focal</i>	40
III.	PROCEDIMIENTO EXPERIMENTAL	44
3.1	Procedimiento Experimental.....	44
3.1.1	<i>Desarrollo de pruebas de campo para BSD mediante Lenovo Ideapad y Delta LattePanda 3</i>	44
3.1.1.1	<i>Muestras de resultados obtenidos en las pruebas BSD</i>	45
3.1.2	<i>Desarrollo de pruebas de campo para FCW mediante Lenovo Ideapad y Delta LattePanda 3</i>	52
3.1.2.1	<i>Muestras de resultados obtenidos en las pruebas FCW</i>	53
IV.	DISEÑO ESTADÍSTICO INFERENCIAL	57
4.1	Contraste de hipótesis para probar: La tasa global de éxito del prototipo.....	60
4.1.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	62
4.1.1.1	<i>Hipótesis y valores planificados</i>	62

4.1.1.2	<i>Cálculo de la potencia de la muestra</i>	63
4.1.2	<i>Prueba de hipótesis</i>	64
4.1.2.1	<i>Hipótesis estadísticas y nivel de significancia</i>	64
4.1.2.2	<i>Estadístico de prueba</i>	64
4.1.2.3	<i>Cálculo del estadístico de prueba</i>	65
4.1.2.4	<i>Decisión</i>	66
4.1.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	66
4.2	Caso 1: contraste de hipótesis para probar la tasa general de éxito del prototipo Lenovo Ideapad ante eventos de los sistemas FCW y BSD.....	68
4.2.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	69
4.2.1.1	<i>Hipótesis y valores planificados</i>	69
4.2.1.2	<i>Cálculo de la potencia de la muestra</i>	70
4.2.2	<i>Prueba de hipótesis</i>	71
4.2.2.1	<i>Hipótesis estadística y nivel de significancia</i>	71
4.2.2.2	<i>Estadístico de prueba</i>	71
4.2.2.3	<i>Cálculo del estadístico de prueba</i>	72
4.2.2.4	<i>Decisión</i>	73
4.2.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	73
4.3	Caso 2: contraste de hipótesis para probar la tasa general de éxito del prototipo LattePanda Delta 3 ante eventos de los sistemas FCW y BSD.....	75
4.3.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	75
4.3.1.1	<i>Hipótesis y valores planificados</i>	76
4.3.1.2	<i>Cálculo de la potencia de la muestra</i>	76
4.3.2	<i>Prueba de hipótesis</i>	78
4.3.2.1	<i>Hipótesis estadística y nivel de significancia</i>	78
4.3.2.2	<i>Estadístico de prueba</i>	78
4.3.2.3	<i>Cálculo del estadístico de prueba</i>	79
4.3.2.4	<i>Decisión</i>	80
4.3.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	80
4.4	Caso 3: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo Lenovo Ideapad ante eventos del sistema de BSD.....	82
4.4.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	82
4.4.1.1	<i>Hipótesis y valores estadísticos</i>	83
4.4.1.2	<i>Cálculo de la potencia de la muestra</i>	83
4.4.2	<i>Prueba de hipótesis</i>	84
4.4.2.1	<i>Hipótesis estadística y nivel de significancia</i>	84

4.4.2.2	<i>Estadístico de prueba</i>	85
4.4.2.3	<i>Cálculo del estadístico de prueba</i>	85
4.4.2.4	<i>Decisión</i>	87
4.4.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	87
4.5	Caso 4: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo Lenovo Ideapad ante eventos del sistema de FCW	88
4.5.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	89
4.5.1.1	<i>Hipótesis y valores planificados</i>	89
4.5.1.2	<i>Cálculo de la potencia de la muestra</i>	90
4.5.2	<i>Prueba de hipótesis</i>	91
4.5.2.1	<i>Hipótesis estadística y nivel de significancia</i>	91
4.5.2.2	<i>Estadístico de prueba</i>	91
4.5.2.3	<i>Cálculo del estadístico de prueba</i>	92
4.5.2.4	<i>Decisión</i>	93
4.5.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	93
4.6	Caso 5: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de BSD	95
4.6.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	95
4.6.1.1	<i>Hipótesis y valores planificados</i>	96
4.6.1.2	<i>Cálculo de la potencia de la muestra</i>	96
4.6.2	<i>Prueba de hipótesis</i>	97
4.6.2.1	<i>Hipótesis estadística y nivel de significancia</i>	97
4.6.2.2	<i>Estadístico de prueba</i>	98
4.6.2.3	<i>Cálculo del estadístico de prueba</i>	98
4.6.2.4	<i>Decisión</i>	99
4.6.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	100
4.7	Caso 6: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de FCW.....	101
4.7.1	<i>Cálculo de la potencia de la muestra empleada en el estudio</i>	102
4.7.1.1	<i>Hipótesis y valores planificados</i>	102
4.7.1.2	<i>Cálculo de la potencia de la muestra</i>	103
4.7.2	<i>Prueba de hipótesis</i>	104
4.7.2.1	<i>Hipótesis estadística y nivel de significancia</i>	104
4.7.2.2	<i>Estadístico de prueba</i>	104
4.7.2.3	<i>Cálculo del estadístico de prueba</i>	105
4.7.2.4	<i>Decisión</i>	106

4.7.2.5	<i>Intervalo de confianza unilateral de 95% para p</i>	106
V.	ANÁLISIS DE RESULTADOS	109
5.1	Análisis de los resultados obtenidos mediante Prototipo global (Lenovo Ideapad y LattePanda Delta 3)	109
5.2	Análisis de los resultados obtenidos mediante Lenovo Ideapad	110
5.2.1	<i>Interpretación de resultados</i>	112
5.3	Análisis de los resultados obtenidos mediante LattePanda Delta 3	113
5.3.1	<i>Interpretación de resultados</i>	114
5.4	Comparación del posprocesamiento del sistema entre Lenovo Ideapad y LattePanda Delta 3	116
5.4.1	<i>Tiempos de detección</i>	116
5.4.2	<i>Comparación Individual</i>	120
5.4.3	<i>Memoria RAM</i>	121
5.4.4	<i>Rendimiento térmico y CPU</i>	122
VI.	CONCLUSIONES	124
VII.	TRABAJOS FUTUROS	131
7.1	Detección de objetos en baja iluminación	131
7.2	Profundidad	131
7.3	Seguimiento de objetos (Radar)	131
VIII.	BIBLIOGRAFÍA	132
APÉNDICE A.		135

ÍNDICE DE ILUSTRACIONES

Ilustración 1. Tipos de distracciones observadas durante el año 2020 en México.	2
Ilustración 2. Accidentes de tránsito terrestre en zonas urbanas año 2021 en México.	3
Ilustración 3. Impacto por alcance en la parte delantera.	3
Ilustración 4. Impacto lateral o Volcadura por impacto lateral.	4
Ilustración 5. Total del Parque vehicular circulante año 2022 en México.	5
Ilustración 6. Prueba de impacto frontal realizada por NCAP y IIHS, 2017.	7
Ilustración 7. Reducción de accidentes automovilísticos utilizando ADAS en EUA, 2021.	9
Ilustración 8. Posicionamiento de las cámaras en el vehículo sujeto.	13
Ilustración 9. Arquitectura PyTorch (flujo de trabajo).	15
Ilustración 10. Vehículo objetivo adelantando al vehículo sujeto.	18
Ilustración 11. Vehículo objetivo entrando en una zona de 30 metros con velocidad constante.	18
Ilustración 12. Vehículo objetivo aproximándose al vehículo sujeto.	19
Ilustración 13. Vehículo objetivo entrando en una zona de 10 metros con velocidad constante.	20
Ilustración 14. Comparativa de velocidad de diferentes modelos de detección de objetos.	23
Ilustración 15. Arquitectura de YOLO V4.	23
Ilustración 16. (A) Imagen de entrada al modelo.	25
Ilustración 17. (B) Resultado del modelo YOLOv4.	25
Ilustración 18. (A) Imagen de entrada al modelo.	25
Ilustración 19. (B) Bloques residuales del modelo.	25
Ilustración 20. (A) Probabilidad de puntuación.	26
Ilustración 21. (B) Resultado de puntuación.	26
Ilustración 22. Funcionamiento de la etapa bloques residuales del modelo YOLO IOU.	27
Ilustración 23. Funcionamiento de la etapa bloques residuales del modelo YOLO umbral de selección.	28
Ilustración 24. Funcionamiento de la etapa bloques residuales del modelo YOLO selección de cuadrícula.	28
Ilustración 25. Funcionamiento de la etapa bloques residuales del modelo YOLO cuadro delimitador.	29
Ilustración 26. Comparativo de velocidad y precisión de YOLO v4.	30
Ilustración 27. Diagrama de flujo del programa para la detección de objetos en Python.	36
Ilustración 28. Interfaz de usuario mediante Python.	38
Ilustración 29. Configuración de la adquisición en tiempo real.	39

Ilustración 30. Configuración de la cámara lateral centrada en el pilar A del lado del conductor.	39
Ilustración 31. Configuración de la cámara frontal centrada en el parabrisas frontal.....	40
Ilustración 32. Configuración punto y distancia focal.	42
Ilustración 33. Vehículo objetivo adelantando al vehículo sujeto por ambos carriles.....	44
Ilustración 34. Vehículo objetivo entrando en una zona de 5 metros con velocidad objetivo.....	45
Ilustración 35. Vehículo sujeto aproximándose al vehículo objetivo.	52
Ilustración 36. Vehículo objetivo entrando en una zona de 10 metros con velocidad objetivo.....	53
Ilustración 37. Gráfica de la distribución normal estándar.	63
Ilustración 38. Gráfica de la distribución binomial para n (2970).	66
Ilustración 39. Gráfica de la distribución de F (5602,338).	67
Ilustración 40. Gráfica de la distribución binomial para n (2250).	73
Ilustración 41. Gráfica de la distribución de F (4252,250).	74
Ilustración 42. Gráfica de la distribución binomial para n (720).	80
Ilustración 43. Gráfica de la distribución de F (1354,88).	81
Ilustración 44. Gráfica de la distribución binomial para n (1500).	86
Ilustración 45. Gráfica de la distribución de F (2822,180).	88
Ilustración 46. Gráfica de la distribución binomial para n (750).	93
Ilustración 47. Gráfica de la distribución de F (1432,70).	94
Ilustración 48. Gráfica de la distribución binomial para n (480).	99
Ilustración 49. Gráfica de la distribución de F (894,68).	100
Ilustración 50. Gráfica de la distribución binomial para n (240).	106
Ilustración 51. Gráfica de la distribución de F (462,20).	107
Ilustración 52. Comparación de tiempo de detección entre dispositivos	116
Ilustración 53. Comparación de tiempo de detección entre prototipos.....	123
Ilustración 54. Comparación de tiempo de detección entre prototipos.....	123

ÍNDICE DE TABLAS

Tabla 1. Dimensiones del vehículo sujeto.	16
Tabla 2. Dimensiones del vehículo objetivo.....	16
Tabla 3. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona crítica.	46
Tabla 4. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona precautoria.	47
Tabla 5. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona riesgo bajo.....	48
Tabla 6. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona crítica.....	49
Tabla 7. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona precautoria.....	50
Tabla 8. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona riesgo bajo.	51
Tabla 9. Muestra de pruebas realizadas en campo para FCW (frontal) zona crítica.	54
Tabla 10. Muestra de pruebas realizadas en campo para FCW (frontal) zona precautoria.	55
Tabla 11. Muestra de pruebas realizadas en campo para FCW (frontal) zona riesgo bajo.	56
Tabla 12. Decisiones en la prueba de hipótesis	57
Tabla 13. Resultados obtenidos pruebas BSD realizadas en campo para prototipo 1.....	109
Tabla 14. Resultados obtenidos pruebas FCW realizadas en campo para prototipo 1.....	110
Tabla 15. Resultados obtenidos pruebas realizadas en campo para BSD (lado piloto).....	111
Tabla 16. Resultados obtenidos pruebas realizadas en campo para BSD (lado copiloto).....	111
Tabla 17. Resultados obtenidos pruebas realizadas en campo para FCW (frontal).	111
Tabla 19. Resultados obtenidos pruebas realizadas en campo para BSD (lado copiloto).....	114
Tabla 20. Resultados obtenidos pruebas realizadas en campo para FCW (frontal).	114
Tabla 23. Rendimiento de la memoria RAM en Lenovo Ideapad Gaming 3 durante detecciones.	121
Tabla 24. Rendimiento de la memoria RAM en LattePanda Delta 3 durante detecciones.....	121
Tabla 25. Resultados obtenidos durante la realización de las pruebas en ambos prototipos.....	123

ÍNDICE DE ECUACIONES

Ecuación 1. Representación vectorial para cuadros delimitadores.....	26
Ecuación 2. Distancia en metros hacia un objeto.	40
Ecuación 3. Distancia focal de la cámara en función de la distancia al objeto.	41
Ecuación 4. Expresión de la potencia de la muestra.....	61
Ecuación 5. Expresión de la potencia unilateral.	63
Ecuación 6. Expresión del Valor p.	64
Ecuación 7. Expresión para la probabilidad de fracaso.....	65
Ecuación 8. Expresión de la función de probabilidad binomial.	65
Ecuación 9. Expresión del intervalo de confianza exacto de Clopper-Pearson.....	66
Ecuación 10. Expresión de la Media de una muestra.	118
Ecuación 11. Expresión de la Desviación Estándar de una muestra.	118
Ecuación 12. Expresión de la Diferencia de Cuadrados de una muestra.....	119
Ecuación 13. Expresión Suma de Cuadrados de una muestra.	119
Ecuación 14. Expresión de la Varianza de una muestra.	120

RESUMEN

El presente caso de estudio está enfocado en desarrollar un sistema de alerta y monitoreo de conducción, ofreciendo una solución a las limitantes de seguridad en los vehículos ligeros de generaciones actuales y previas. El desarrollo del dispositivo contribuye a complementar y enriquecer la seguridad de los ocupantes de los vehículos ligeros y usuarios en vía pública. El análisis está basado, en las tecnologías actuales de sistemas avanzados de asistencia al conductor (ADAS), las cuales han logrado contribuir a evitar más de 30,000 siniestros al año en vehículos ligeros de gama alta - media en países desarrollados como Estados Unidos de América (Fundación MAPFRE, 2022).

En el presente trabajo se reporta el caso de estudio realizado a través de pruebas de campo utilizando un prototipo funcional capaz de emitir alertas audiovisuales a los conductores y pasajeros del vehículo sujeto a prueba al percibir riesgos críticos y precautorios circundantes al vehículo. Los programas aprendizaje automático (ML) se realizaron mediante Python y Open CV para garantizar una óptima comunicación en tiempo real. Así mismo, el prototipo es capaz de ser utilizado como una herramienta de posprocesamiento para el análisis de imágenes que se hallan registrado con anterioridad.

A partir de las pruebas de campo se obtuvo una tasa de detección de vehículos circundantes del 93.4% para las muestras de detección del Sistema de Advertencia de Colisión Frontal (FCW, por sus siglas en inglés) y del Sistema de Detección de Puntos Ciego (BDS, por sus siglas en inglés) recabadas.

Palabras Clave: BDS, LDW, FCW, ADAS, ML, Sistemas avanzados de asistencia al conductor.

ABSTRACT

The present case study is focused on the development of a driving alert and monitoring system, addressing the safety limitations of vehicles from both current and previous generations. The creation of this device aims to enhance and supplement the safety of any vehicle occupants and public road users. The analysis is based on the current technologies of advanced driver assistance systems (ADAS), which have contributed to prevent over 30,000 accidents annually in mid-to-high-end trims vehicles in developed countries such as the United States of America (Foundation MAPFRE, 2022).

This investigation was conducted through field tests using a functional prototype capable of issuing audiovisual alerts to drivers and passengers of the vehicle under test when detecting critical and precautionary risks surrounding the vehicle. The machine learning (ML) programs were developed using Python and OpenCV to ensure optimal real-time communication. Furthermore, the prototype is capable of being utilized as a post-processing tool for the analysis of previously recorded images.

Field tests were conducted under specific driving conditions to evaluate the effectiveness and reliability of the system. The tests included scenarios such as urban traffic and realistic weather conditions. The results showed a detection rate of 93.4% for surrounding vehicles in the collected samples of front collision warning (FCW) and blind spot detection (BDS).

Keywords: BDS, LDW, FCW, ADAS, ML, Advanced driving safety system.

I. INTRODUCCIÓN

1.1 Naturaleza y Dimensión del Estudio

1.1.1 ADAS

Los Sistemas Avanzados de Asistencia al Conductor (ADAS), engloban una serie de métodos que mejoran la experiencia de manejo y, sobre todo, la seguridad de los pasajeros. Los sistemas de asistencia a la conducción pueden intervenir de distintas maneras, como, asistencias en el control de la autonomía del combustible, frenos, velocidad, etc. De igual manera, pueden contribuir en la asistencia de cambio de carril, aparcamiento, manejo autónomo, o en el equipo de señalización, ya sea hacia otros conductores o en la comunicación entre el vehículo y el conductor.

El propósito de los ADAS es prevenir o reducir los errores de los conductores y mejorar la seguridad en el tráfico y el transporte. Los beneficios de su implementación son potencialmente considerables, esto debido a que conllevan a una disminución significativa en el número de accidentes con pérdidas humanas y los costos económicos. Estos sistemas avanzados de seguridad tales como, Sistema de mantenimiento de carril (LKAS, Lane Keeping Assist System), Sistema de Advertencia de Cambio de Carril (LDW), Sistema de Advertencia de Colisión Frontal (FCW, Forward Collision Warning System), Sistema de Frenado Autónomo de Emergencia (AEB, Autonomous Emergency Breaking), entre otros, son limitados a los automóviles de gama baja-media-alta en México.

1.1.1.1 Causas principales en los accidentes de tránsito

La principal causa en los accidentes automovilísticos se atribuye a un “error o factor humano”, siendo las deficiencias o distracciones de manejo el principal factor de riesgo. Alrededor del 90% de todos los accidentes de tráfico se deben a errores humanos o distracciones (Seguros MAPFRE, 2023), por ejemplo, debido a fatiga, falta de atención o consumo de bebidas o alimentos. Según Vallet, “el error humano o distracción se define

generalmente como una pérdida del estado de alerta” (Vallet, 2001). Las principales distracciones observadas durante la conducción en México, 2020 se observa en la figura 1.

Tipos de distracciones observadas durante la conducción en el año 2020

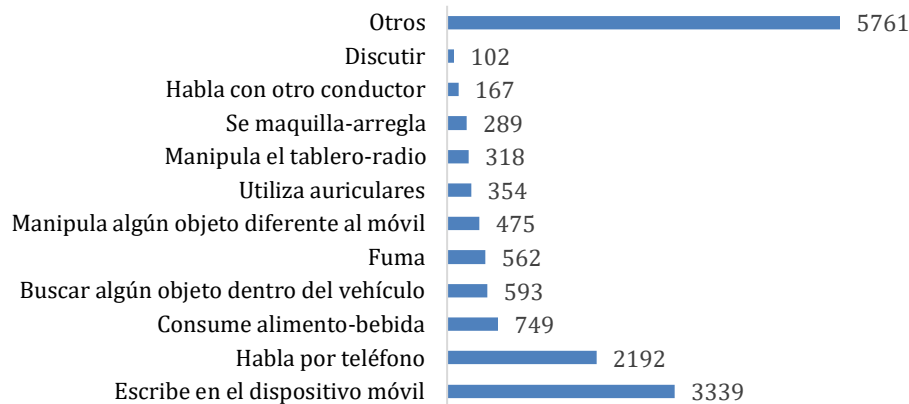


Ilustración 1. Tipos de distracciones observadas durante el año 2020 en México.

Fuente: Secretariado Técnico del Consejo Nacional para la Prevención de Accidentes. (2020). *SS*.

1.1.1.2 Costo socioeconómico de los accidentes viales

Los costos de los accidentes de tráfico para la sociedad son enormes, tanto en términos de sufrimiento humano como de pérdidas económicas. Como se observa en la figura 2, tan sólo en México, alrededor de 60,000 (9%) personas han resultado heridas en accidentes de tránsito y al menos 3,800 (1%) han fallecido en dichos accidentes en los últimos años, según datos del Instituto Nacional de Estadística y Geografía (INEGI, 2022). La congestión del tráfico habitual y la que sigue a accidentes de tráfico, es una molestia diaria, predominantemente presente en los lugares económicamente más complejos.

ACCIDENTES DE TRÁNSITO TERRESTRE EN ZONAS URBANAS, POR CLASE EN EL AÑO 2021

■ Total de accidentes ■ Solo daños materiales ■ No fatal ■ Fatal




Ilustración 2. Accidentes de tránsito terrestre en zonas urbanas año 2021 en México.

Fuente: INEGI. (2021). Estadística de Accidentes de Tránsito Terrestre en Zonas Urbanas y Suburbanas.

1.1.1.3 Tipos de siniestros viales con mayor riesgo

Existen diferentes tipos de siniestros vehiculares, de los cuales típicamente resultan en heridas o pérdidas más catastróficas que otros. Algunos factores que determinan el nivel de gravedad de un siniestro vehicular son: la velocidad de impacto, tipo de estructura de los vehículos involucrados, uso de cinturón de seguridad, etc. Como se mencionó, existen tipos de accidentes automovilísticos que son propiamente más peligrosos que otros como (Ilustración 3 y 4):

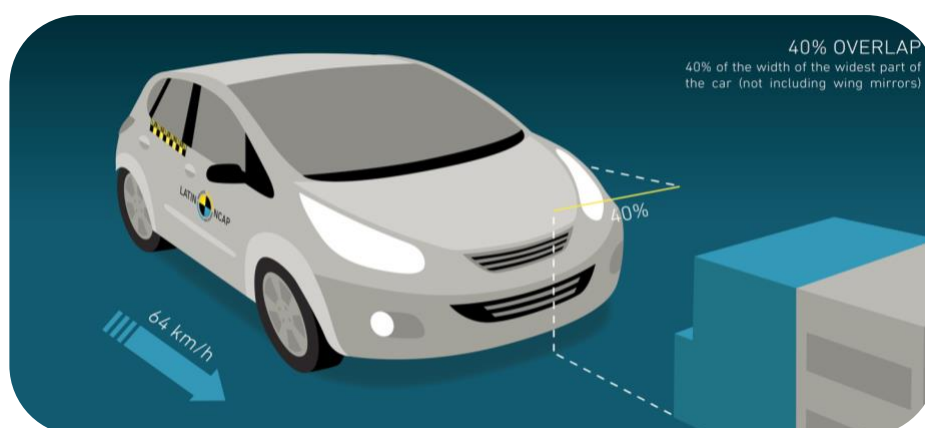



Ilustración 3. Impacto por alcance en la parte delantera.

Fuente: LATIN NCAP. (2023). Impacto Frontal y Lateral.



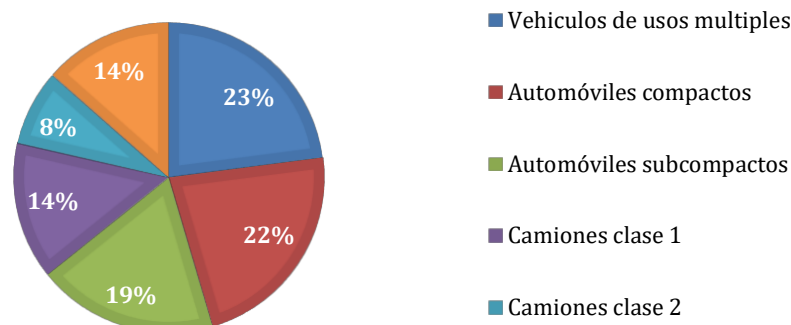
*Ilustración 4. Impacto lateral o Volcadura por impacto lateral.
Fuente: LATIN NCAP. (2023). Impacto Frontal y Lateral.*

Estos accidentes, son prevenibles mediante las tecnologías ADAS, por lo cual, un sistema de bajo costo y multifuncional capaz de alertar en caso de cambio de advertencia de punto ciego y advertencia de colisión frontal es útil para ayudar al conductor distraído. Aún y cuando los sistemas de monitoreo ya están disponibles en el mercado, el parque vehicular en México está determinado por vehículos utilitarios o de gama baja, de los cuales la seguridad de los ocupantes se encuentra en un segundo plano.

1.1.1.4 Contexto Nacional

La legislación actual en México (NOM-194-SE-2021), la cual entró en vigor en el año 2022, únicamente reglamenta los sistemas de seguridad convencionales a las empresas manufactureras para comercializar sus vehículos en México (SEGOB, 2022). Como se observa en la figura 5, del total del parque vehicular circulante en México, 17.95 (~50%) millones son automóviles, el mayor volumen son vehículos de usos múltiples o utilitarios con 8.21 millones de unidades (22.94%), seguido de los automóviles compactos con 8.05 millones de unidades (22.49%); y los automóviles subcompactos con 6.73 millones de unidades (18.81%). Tan solo 4.83 millones de unidades que corresponde al 13.51 por ciento del total, está integrado por los automóviles deportivos y automóviles de lujo (INEGI, 2021).

TOTAL DEL PARQUE VEHICULAR CIRCULANTE EN MÉXICO 35.79 (EN MILLONES), 2022



*Ilustración 5. Total del Parque vehicular circulante año 2022 en México.
Fuente: INEGI. (2022). Vehículos de motor registrados en circulación.*

Los vehículos dependiendo de su año de fabricación y clase, podrían incluir algunos de los sistemas de seguridad ADAS. En particular, el mercado mexicano ha mostrado un retraso significativo en estas tecnologías en la última década, que obedece, a distintos factores que en conjunto han evitado la implementación de estas tecnologías. Esto ha llevado a los consumidores a buscar alternativas más económicas para sus vehículos en cuestiones de seguridad agregada a sus vehículos. Como son el caso de los módulos genéricos de sensores y cámaras de reversa.

1.1.1.5 Medidas adoptadas para reducir los accidentes viales en México

A lo largo de la década pasada en México, la seguridad vial aplicable falló en la reducción de decesos por accidentes o muertes viales como ya se ha mencionado. Del año 2010 al 2018 hubo alrededor de 145,000 lesionados o decesos, de los cuales el 64% fueron muertes de usuarios vulnerables y por otro lado los peatones, representan el 48% del total de muertes de ese periodo (INEGI, 2022). Por lo cual, cobra importancia una reforma a la norma, que la Secretaría de Economía. - Unidad de Normatividad, Competitividad y Competencia. En esta propuesta, se busca que sean considerados como obligatorios los siguientes sistemas de seguridad en todos los vehículos nuevos comercializados en México. Los sistemas solicitados

son los siguientes: Control electrónico de estabilidad, Adaptador inteligente de velocidad, Caja negra y Alerta de desviación de carril.

1.1.2 Antecedentes

1.1.2.1 Análisis crítico de la literatura

Una de las principales causas de los accidentes viales en las avenidas y carreteras de alta velocidad está determinada por los límites de percepción y reacción del conductor ante distracciones y riesgos en el camino. Actualmente, la Norma Oficial Mexicana establece una serie de requisitos que los vehículos deben cumplir en México para ser comercializados, estos sin llegar a ser requeridos sistemas de seguridad modernos a los fabricantes como en países desarrollados. Algunos de los principales puntos de seguridad son los siguientes: Sistema de frenado, Frenos ABS, Cinturones de seguridad, Recordatorio de uso de cinturón de seguridad, Bolsas de aire, entre otras (CESVIMAP,2017).

Según datos de Asociación Mexicana de la Industria Automotriz, las regulaciones de fabricación tienen 10 años de retraso en comparación con las de países desarrollados como la Unión Europea o EUA, lo que particularmente resulta en medidas de seguridad deficientes y fallas de diseño de varios de los vehículos que se venden en México (AMIA, 2020).

Uno de los vehículos que fue comercializado y que a la fecha aún se encuentra transitando en la vía pública es el caso del vehículo denominado “Tsuru” del fabricante Nissan Motor Company. En un análisis y demostración realizado por la IIHS y GNCAP, dirigido a dos vehículos Nissan, Versa 2016 y el mencionado anteriormente, se observa la gran diferencia en sistemas de seguridad, sometidos a una prueba de choque frontal a 56 km/h, en el cual el “Tsuru” resulto prácticamente destruido (IIHS & NCAP, 2016).




Ilustración 6. Prueba de impacto frontal realizada por NCAP y IIHS, 2017.

Fuente: Insurance Institute for Highway Safety (IIHS), Global NCAP, Latin NCAP. (2016). Nissan Finally Take Zero Star Tsuru Out of Production Following NCAP Campaign.

Este vehículo es comúnmente utilizado por los transportistas, el cual no cuenta con bolsas de aire, frenos antibloqueo o control de estabilidad para ajustar la velocidad de los neumáticos y evitar el derrape, sin mencionar algún sistema ADAS.

Este tipo de vehículos por mencionar algunos siguen transitando en México sin ninguna restricción o prohibición. Algunos de los vehículos más utilizados en México con bajo nivel de sistemas de seguridad son los siguientes (El Universal, 2022):

- Chevrolet Aveo. (Ningún sistema de seguridad tradicional o avanzado, generación 2011-2019).
- Nissan Tiida. (Ningún sistema de seguridad tradicional o avanzado, generación 2006-2013).
- Nissan Tsuru. (Ningún sistema de seguridad tradicional o avanzado, generación 2003-2015).
- Nissan Versa. (Cumple con sistema de seguridad tradicional, generación 2012-2019).

- Nissan March. (Cumple con sistema de seguridad tradicional, generación 2013-2020).

Esto abre una oportunidad muy importante para diseñar e implementar un sistema que sea capaz de brindar mayor seguridad a los ocupantes y apoyar a reducir la siniestralidad vial en México.

1.1.3 Metodología de la Investigación

1.1.3.1 Declaración del problema y propósito del estudio

En México se registran alrededor 340,000 accidentes de tránsito por año en zonas urbanas debido a distractores o errores humanos, alcanzando una cifra de alrededor de 80,000 personas heridas debido a estos accidentes (INEGI, 2022). En el presente caso de estudio se propone utilizar un conjunto de diferentes cámaras y sensores para captar los vehículos circundantes, estacionarios y en movimiento en el tráfico. Este dispositivo permitirá emitir alertas y monitorear con respecto a una posible colisión con el vehículo delante y detección de punto ciego en el camino. Este desarrollo ayudaría a complementar y mejorar la seguridad de los pasajeros, con base, en las limitaciones actuales de seguridad en los vehículos comercializados en México.

1.1.3.2 Importancia y justificación del estudio

En México mueren al menos 4,400 personas en accidentes viales al año según el INEGI (INEGI, 2021). En la actualidad las colisiones y atropellamientos, son la octava causa de muerte en México en personas de todas las edades, y la primera entre niños y adultos jóvenes de 5 a 29 años (INEGI, 2021). La Norma Oficial Mexicana establece una limitada serie de condiciones de seguridad que los vehículos deben cumplir en México para poder ser comercializados.

Los sistemas de seguridad avanzados ADAS, han logrado reducir accidentes automovilísticos de varias maneras, tales como:

- Las tecnologías de advertencia de colisión frontal redujeron los choques de adelante hacia atrás en un 27 %.
- Las tecnologías de advertencia de colisión frontal con freno automático redujeron los choques de adelante hacia atrás en un 50 %.
- Las tecnologías de detección de puntos ciego redujeron los accidentes por cambio de carril en un 14 %.

Reducción de accidentes automovilísticos utilizando ADAS en EUA, 2021




Ilustración 7. Reducción de accidentes automovilísticos utilizando ADAS en EUA, 2021.

Fuente: National Highway Traffic Safety Administration (NHTSA). (2022). *Tecnologías de asistencia al conductor.*

Estos datos fueron obtenidos del Instituto de Datos de Pérdida de Carreteras de Estados Unidos de América (NHTSA, 2022).

1.1.3.3 Hipótesis general de investigación

El resultado material del presente trabajo de investigación es desarrollar un prototipo funcional que es capaz de monitorear el tráfico vehicular y peatonal circundante y emitir alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales tanto para FCW (Forward Collision Warning System o Sistema de Advertencia de Colisión Frontal) como de BSD (Blind Spot Detection System o Sistema de Detección de Puntos Ciego). El desarrollo del prototipo se lleva a cabo utilizando las tecnologías de Machine Learning y de Deep Learning para la detección de objetos disponible durante el proceso de investigación y en el marco de un criterio de eficiencia económica: lograr el objetivo buscado al mínimo costo.

En particular, en la etapa de desarrollo del prototipo se pretende alcanzar una tasa de advertencias correctas de al menos 93%.

Las hipótesis estadísticas nula es:

$H_0: p \geq 0.93$ La proporción global de éxitos del prototipo de sistema de advertencia ante eventos tanto de colisión frontal como lateral es por lo menos de 93%.

1.1.3.4 Objetivo general de la investigación

Desarrollar un prototipo funcional capaz de monitorear el tráfico vehicular y peatonal circundante y emitir alertas audiovisuales al conductor y pasajeros de posibles riesgos viales como FCW y BSD, lo cual permitirá expandir los sistemas de seguridad actuales presente en la mayor parte del parque vehicular circulante en México.

Utilizando tecnologías de seguridad asistida (ADAS) para generar alertas audiovisuales, buscando favorecer la prevención de posibles colisiones con los vehículos y/o peatones circundantes. Esto por consiguiente involucrara una mejora a los requerimientos actuales establecidos en la normativa Oficial Mexicana.

1.1.3.5 Objetivos específicos de la investigación

1. Estimar la tasa general de éxito del prototipo del sistema de advertencia de detección de posibles eventos de punto ciego y frontal con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.
 - 1) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo ante eventos de posible colisión frontal y punto ciego es mayor o igual a 93%.
2. Estimar la tasa general de éxito del prototipo de sistema del sistema de advertencia de detección de posibles eventos de punto ciego y frontal con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.
 - 2) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Latte ante eventos de posible colisión frontal y punto ciego es por lo menos de 93%.

3. Estimar la tasa particular de éxito con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto del sistema de advertencia de colisión frontal, la cual debe ser al menos de 93%.
 - 3) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%
4. Estimar la tasa particular de éxito con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto del sistema de advertencia de detección de punto ciego, la cual debe ser al menos de 93%.
 - 4) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de detección de punto ciego es por lo menos de 93%.
5. Estimar la tasa de particular de éxito con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto del sistema de advertencia de colisión frontal, la cual debe ser al menos de 93%.
 - 5) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.
6. Estimar la tasa de éxito del prototipo del sistema de advertencia de detección de punto ciego con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.
 - 6) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de detección de punto ciego es por lo menos de 93%.
7. Diseñar un sistema de advertencia de colisión frontal, capaz de emitir una alerta audiovisual en la consola central del automóvil.


8. Diseñar un sistema de detección de punto ciego, capaz de emitir una alerta audiovisual en la consola central del automóvil.

II. MATERIALES Y METODOLOGÍA

2.1 Materiales

2.1.1 Evaluación de materiales a utilizar

Para los diferentes casos, se dispondrá de dos cámaras tipo Logitech HD Pro Webcam c920 para el caso de BSD y un cámara tipo Logitech FHD Brio 100 para el caso de FCW. Estas cámaras se montarán en la parte inferior del parabrisas y pilares A del vehículo sujeto tipo KIA Sorento 2018. Logrando capturar los laterales y frente del vehículo como se aprecia en la siguiente figura 8.



*Ilustración 8. Posicionamiento de las cámaras en el vehículo sujeto.
Fuente: KIA. (2018). Sorento Showroom.*

Para el procesamiento y análisis de las grabaciones se utilizará una computadora con las siguientes características: Lenovo Ideapad 3 AMD Ryzen 7, Nvidia GTX 1060Ti y un dispositivo LattePanda Delta 3 con pantalla tipo LCD integrada.

Se utilizará la cámara Logitech HD Pro Webcam c920 para realizar el análisis de video en tiempo real, capaz de realizar compresión de video dentro de la cámara. Esta función permite ahorrar tiempo computacional, además tiene la capacidad de grabar videos de hasta 1920 x 1080 pixeles que son compatibles con Python y Open CV.

2.1.2 Ambientes utilizados para el desarrollo del sistema (Python y Open CV)

2.1.2.1 Open CV

OpenCV es una biblioteca de funciones de programación dirigida específicamente a la visión por computadora (OpenCV Organization, 2024) en tiempo real. Esta es una plataforma de código abierto y de uso gratuito. Es una importante biblioteca de código abierto de visión por computadora, aprendizaje automático y procesamiento de imágenes. Actualmente, tiene un papel importante en el procesamiento de actividades en tiempo real para los sistemas actuales. Se implementará para procesar fotografías y videos, reconocer personas y vehículos. De igual manera, Python es capaz de procesar la estructura OpenCV para su revisión, ya que cuenta con un gran repertorio de módulos y herramientas avanzadas, logrando combinarse con diferentes bibliotecas como NumPy. Es accesible en la gran mayoría de sistemas operativos como Windows, Linux, iOS, etc., con Python, C++, Java como interfaces.

2.1.2.2 Python-Pytorch

Python es un lenguaje de programación de alto nivel, orientado a objetos y con semántica dinámica. Sus diferentes características lo hacen una gran opción para el desarrollo rápido de aplicaciones, así como para su uso como lenguaje de secuencias de comandos capaz de conectar componentes existentes entre sí (Python Foundation, 2024).

PyTorch es un paquete que proporciona dos características de alto nivel: Cálculo de tensor (como NumPy) con una alta eficiencia de GPU y redes neuronales profundas construidas en un sistema de auto graduación basado en cinta. La combinación de estas herramientas permite utilizar modelos para la detección de vehículos en tiempo real (Paske, Gross, Massa & Lerer, 2019).

Una de las principales aplicaciones de PyTorch como se observa en la figura 9, es la identificación de objetos dentro de imágenes o videos mediante modelos pre entrenados. Con base en el concepto de que cada objeto tiene características únicas. Estas características ayudan a clasificar los objetos en diferentes clases. Por lo cual, se utilizará parte de esta herramienta

de “Deep & Machine Learning” para el análisis y clasificación de los casos (BSD y FCW) (Paske, Gross, Massa & Lerer, 2019).

FLUJO DE TRABAJO DE PYTORCH

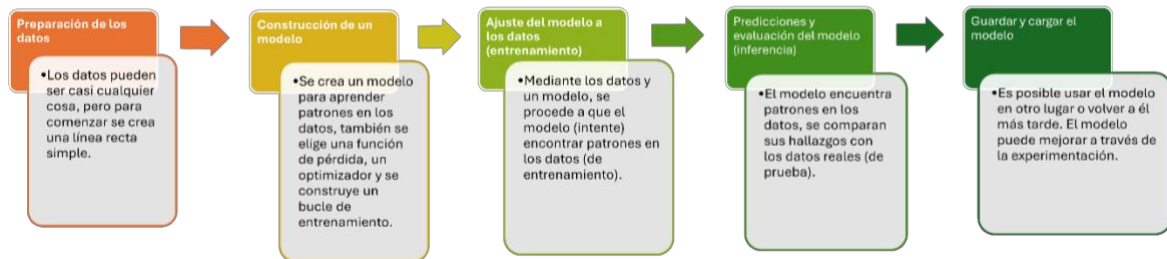


Ilustración 9. Arquitectura PyTorch (flujo de trabajo). Fuente: PyTorch Team. (2023). *Training with PyTorch*.

2.2 Metodología

2.2.1 Evaluación de los métodos de preparación para las pruebas

2.2.1.1 Condiciones iniciales del pavimento

La ubicación de la prueba debe realizarse bajo las siguientes consideraciones:

- Sobre una superficie plana (sin irregularidades).
- Sin humedad visible en la superficie pavimentada con asfalto o de concreto.
- La temperatura ambiente durante la prueba debe estar dentro del rango de 5°C - 45°C.
- El rango de visibilidad horizontal deberá ser superior a 150 metros.
- La prueba se debe realizar en condiciones de día.

Con la finalidad de crear las condiciones especificadas, se utilizarán las vías públicas. Utilizando los carriles laterales y las líneas divisoras para su señalización y equipo de protección para el conductor para la obtención y análisis del sistema.

2.2.2 Condiciones iniciales de los vehículos

Se utilizarán los vehículos tal como se entreguen en óptimas condiciones y sin ninguna alteración o modificación realizada por el propietario.

2.2.3 Preparación de los vehículos

Se deberá preparar el equipo de prueba a bordo del vehículo sujeto y la instrumentación para la interfaz de usuario en el vehículo. Posteriormente, instalar los cables, adaptadores y las fuentes de alimentación requeridos para el funcionamiento del equipo e interfaz.

2.2.4 Características físicas de los vehículos

Las dimensiones del vehículo sujeto utilizado en este caso de estudio será la siguiente:

Tabla 1. Dimensiones del vehículo sujeto.

	Dimensiones (m)
Largo (mm)	4,800 mm
Ancho (mm)	1,890 mm
Altura (mm)	1,685 mm
Peso (kg)	1,874 kg

De igual manera, las dimensiones del vehículo objetivo utilizado en este caso de estudio será la siguiente:

Tabla 2. Dimensiones del vehículo objetivo.

	Dimensiones (m)
Largo (mm)	5,115 mm
Ancho (mm)	2,269mm
Altura (mm)	1,740 mm
Peso (kg)	2,770 kg

2.3 Plan de implementación para las pruebas en campo

La planeación de las pruebas a realizar se determinó con base en el protocolo para pruebas de detección de punto ciego por la ASEAN NCAP versión 1 del año 2019 (ASEAN CAP, 2020) y la norma ISO 17387, la cual especifica los requisitos de los sistema y métodos de prueba para los sistemas de ayuda a la decisión de cambio de carril a evaluar.

2.3.1 Plan de implementación para la prueba BSD

Las pruebas se enfocarán en evaluar que los sistemas de advertencia de puntos ciego y de colisión frontal, emiten advertencias cuando es requerido. Para el escenario de advertencia

de puntos ciegos, se analizará cuando el vehículo objetivo adelante al vehículo sujeto en cuestión, la prueba deberá realizarse bajo las siguientes consideraciones.

- El recorrido deberá ser recto y sin interferencias externas en el camino.
- El vehículo sujeto a prueba se conducirá en línea recta a una velocidad constante máxima de $40\text{km/h} \pm 2 \text{ km/h}$.
- El vehículo objetivo de prueba se conducirá en línea recta, de modo que su velocidad de aproximación sea de $10 \text{ km/h} \pm 2 \text{ km/h}$.
- Ambos vehículos deberán ser conducidos de tal manera que la distancia lateral entre el borde exterior de la carrocería del vehículo sujeto y la línea central del vehículo objetivo sea de 2 a 3 metros para la prueba de advertencia en las 3 zonas a evaluar.
- Se realizarán 26 repeticiones de cada secuencia lateral (piloto y copiloto) para determinar la tasa de éxito en cada zona.

La evaluación comenzará cuando ambos vehículos alcancen una velocidad constante de $40 \text{ km/h} \pm 2 \text{ km/h}$ y el vehículo objetivo esté a una distancia menor a los 15 metros de proximidad.

2.3.1.1 Esquematización de la prueba en línea recta para BSD

Al inicio de la prueba el vehículo sujeto y el vehículo objetivo se posicionarán en carriles alternos, pero en paralelo, con el vehículo objetivo rebasando longitudinalmente al vehículo sujeto. Una vez realizado la prueba y completado la captación de mediciones y datos para el lado seleccionado, se deberá repetir en su totalidad la prueba para el lado opuesto.




Ilustración 10. Vehículo objetivo adelantando al vehículo sujeto.

Fuente: Elaboración propia.

Es necesario comprobar la funcionalidad del sistema de BSD, el cual deberá emitir alertas cuando se realiza el escenario en línea recta de acuerdo con el procedimiento y condiciones estipuladas en la planeación de la prueba y el vehículo objetivo descrito en las secciones anteriores. La emisión de alerta para la prueba de BSD se dividirá en tres casos como se observan en la ilustración 11:

- Advertencia crítica (color rojo).
- Advertencia precautoria (color amarillo).
- Advertencia riesgo bajo (color azul).




Ilustración 11. Vehículo objetivo entrando en una zona de 30 metros con velocidad constante.

Fuente: Elaboración propia.

2.3.2 Plan de implementación para la prueba FCW

Para el escenario de advertencia de colisión frontal, se analizará cuando el vehículo objetivo descienda su velocidad y la distancia del vehículo sujeto al vehículo objetivo sea menor a 10 metros, la prueba deberá realizarse bajo las siguientes consideraciones.

- El recorrido debe ser recto y sin interferencias externas en el camino.

- El vehículo sujeto a prueba es conducido en línea recta a una velocidad constante máxima de $35 \text{ km/h} \pm 2 \text{ km/h}$.
- El vehículo objetivo de prueba es conducido en línea recta a una velocidad de 40 km/h .
- Ambos vehículos son conducidos de tal manera que la distancia frontal entre el borde exterior de la defensa delantera del vehículo sujeto y la defensa posterior del vehículo objetivo sea de 10 metros como mínimo para la prueba de advertencia en sus 3 zonas.
- Se realizan 26 repeticiones para determinar la tasa de éxito en cada zona.

La evaluación comenzará cuando ambos vehículos alcancen una velocidad constante de $35 \text{ km/h} \pm 2 \text{ km/h}$ y $45 \text{ km/h} \pm 2 \text{ km/h}$ y el vehículo objetivo esté a una distancia menor a los 10 metros de proximidad.

2.3.2.1 Esquematización de la prueba en línea recta para FCW

Al inicio de la prueba el vehículo sujeto y el vehículo objetivo se conducirán en el mismo carril, pero a una distancia longitudinal de +10 metros, con el vehículo objetivo. El vehículo objetivo pasará a descender su velocidad de manera constante, el vehículo sujeto se aproximará una distancia menor a los 10 metros iniciales por la parte trasera del vehículo objetivo.




Ilustración 12. Vehículo objetivo aproximándose al vehículo sujeto.

Fuente: Elaboración propia.

Es necesario comprobar la funcionalidad del sistema de FCW, el cual deberá emitir alertas cuando se realiza el escenario en línea recta de acuerdo con el procedimiento y condiciones estipuladas en la planeación de la prueba y el vehículo objetivo descrito en las

secciones anteriores. La emisión de alerta para la prueba de FCW se dividirá en tres casos como se observan en la ilustración 13.

- Advertencia crítica (color rojo).
- Advertencia precautoria (color amarillo).
- Advertencia riesgo bajo (color azul).




Ilustración 13. Vehículo objetivo entrando en una zona de 10 metros con velocidad constante.
Fuente: Elaboración propia.

2.4 Desarrollo del sistema para la implementación

Una vez completado la planeación y esquematización de las pruebas a realizar, se iniciará con el desarrollo del sistema de análisis en los ambientes establecidos (Open CV y Python). El desarrollo del sistema consiste en las siguientes secciones:

- Captación de las imágenes/video captadas mediante las cámaras Logitech 920s y Brio 100.
- Posprocesamiento de los archivos en OpenCV y Python.
- Emisión de alerta audiovisual.

La captación de imágenes y video se llevará a cabo mediante Python, al igual que la emisión de la alerta audiovisual. El procesamiento de los archivos para la detección de objetos se llevará a cabo mediante OpenCV y YOLOv4.

El sistema debe ser capaz de realizar el análisis de video en tiempo real, funcionando a bordo durante la conducción del vehículo y almacenando exclusivamente los registros dentro de las zonas de riesgo delimitadas tomando como referencia criterios secundarios para ahorrar tiempo de análisis durante el procesamiento.

2.4.1 Modelo utilizado para el análisis y procesamiento

Una vez inicializado el sistema y habiendo obtenido las imágenes es necesario realizar el procesamiento de cada imagen, para lo cual se revisaron y analizaron diferentes librerías y modelos de Deep Learning para aplicaciones de detección de objetos en tiempo real. Detección de objetos es una técnica utilizada en visión por computadora para la identificación y localización de objetos dentro de una imagen o un video. La localización de imágenes es el proceso de identificar la ubicación correcta de uno o varios objetos mediante cuadros delimitadores, que corresponden a formas rectangulares alrededor de los objetos.

Entrenar un modelo desde cero, conlleva un tiempo considerable y la posibilidad de un prolongado periodo de prueba a fin de que la precisión del modelo entregue resultados óptimos. Una consideración para tener en cuenta es el conjunto de datos con el cual se pre entrenará el modelo. Realizar la adquisición manual del conjunto de datos (consiste en recabar una cantidad considerable de imágenes tipo prueba), las cuales deberán incluir diferentes tipos de vehículos, situaciones y ambientes otorgando robustez al conjunto de datos, de lo contrario esto añade un riesgo en la eficiencia de identificación de objetos en las imágenes. Tomando en consideración lo anterior, se decidió utilizar el algoritmo “You Only Look Once” (YOLO) pre entrenado con Common Objects in Context (MS COCO). Utilizando los pesos de modelos previamente entrenados como YOLO, se logra obtener una buena precisión y rápida respuesta.

2.4.2 Principio y arquitectura de YOLO v4

El modelo YOLO v4 es utilizado para identificar objetos a gran escala. YOLO fue presentado por Joseph Redmon, Santosh Divvala, Ross Girshick y Ali Farhadi en 2015. YOLO utiliza una red única para predecir directamente cuadros delimitadores y clases a partir de imágenes como se puede observar en la figura 15. La velocidad de detección del modelo YOLOv1 fue relativamente rápida. No obstante, YOLOv1 no resulto efectivo para objetos que se encuentren cerca entre sí y objetos pequeños. El modelo YOLOv2 adopto Darknet19 como

red de extracción de características, adaptándose a diferentes tamaños de imágenes y mejorando la precisión de detección para objetos pequeños (Redmon & Farhadi, 2020). Posteriormente, en el año 2018 Joseph Redmon y Ali Farhadi construyeron el modelo YOLOv3 mediante una nueva red de extracción de características Darknet53, introduciendo la idea de redes residuales para permitir que el modelo extraiga características más profundas. El modelo YOLOv3 mejoró aún más la precisión de detección de objetos pequeños, manteniendo la ventaja de la velocidad de detección como se puede observar en la ilustración 14.

El modelo YOLOv4 toma CSPDarknet53 como red troncal, reduciendo la cantidad de cómputo de la red, el consumo de memoria y logrando superar el algoritmo YOLOv3 en velocidad y precisión (DECI, 2023). Como se indicó, YOLOv4 es capaz de lograr una buena precisión (43.5% AP) y, al mismo tiempo, puede ejecutarse en tiempo real.

La ilustración 14, muestra una comparación de respuesta 6 diferentes modelos de detección de objetos. YOLOv4, que corresponde a la cuarta iteración del modelo YOLO, presenta los mejores resultados debido a su capacidad para analizar un mayor número de fotogramas por segundo manteniendo una alta precisión promedio (AP, por sus siglas en inglés). Destaca que, aunque actualmente existen más versiones del modelo YOLO, solo se dispone de una amplia documentación para cuatro de ellas, ya que las versiones restantes aún están en desarrollo continuo.

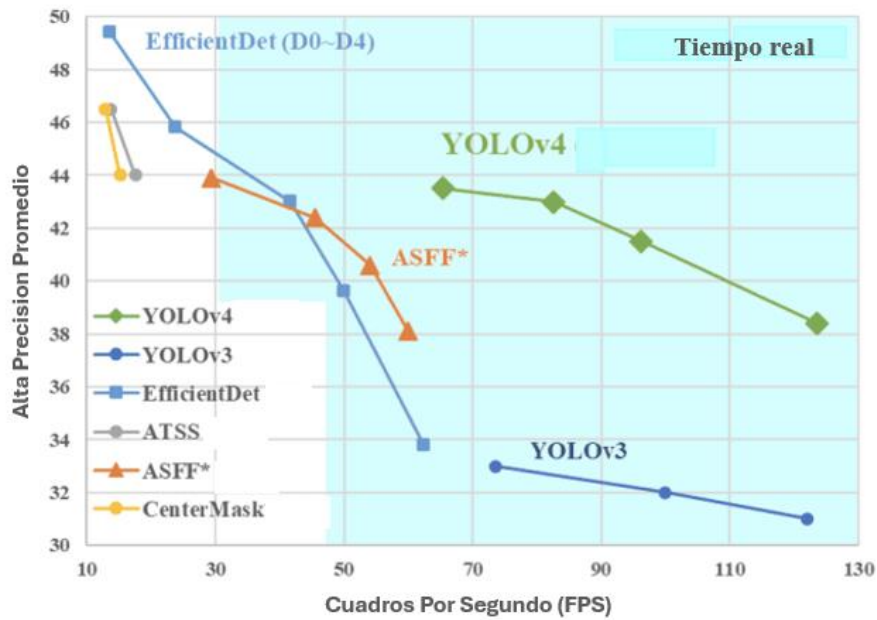


Ilustración 14. Comparativa de velocidad de diferentes modelos de detección de objetos.
 Fuente: Bochkovskiy, A., Wang, C.-Y., & Liao, H.-y. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection.

2.4.2.1 Arquitectura de YOLO v4

La arquitectura del modelo YOLOv4 es similar a otras redes neuronales como GoogleNet, ATSS, entre otras. Como se observa en la ilustración 15, la arquitectura del modelo YOLOv4 tiene un total de 24 capas convolucionales, cuatro capas de agrupación máxima y dos capas completamente conectadas.

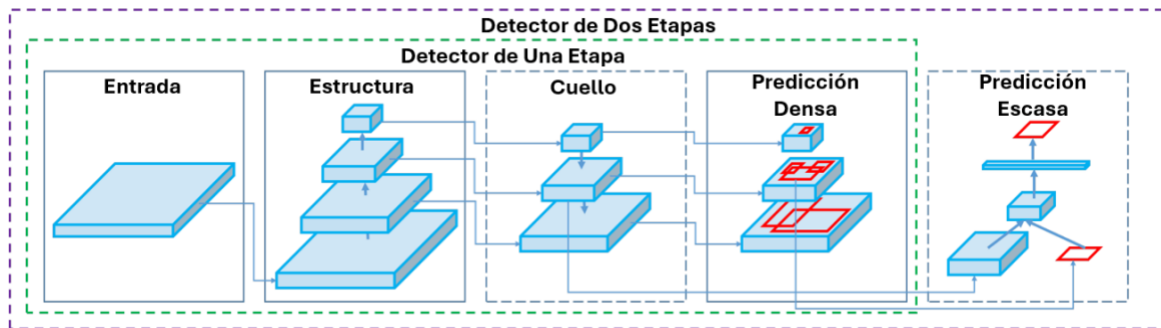


Ilustración 15. Arquitectura de YOLO V4.
 Fuente: Redmon, J. & Farhadi, A. (2020). You Only Look Once: Unified, real-time object detection.

La arquitectura opera de la siguiente manera:

- Reduce el tamaño de la imagen de entrada a 448 pp x 448 pp previo al paso por la red convolucional.
- Posteriormente se aplica una convolución de 1 x 1 para reducir el número de capas, seguida por una convolución de 3 x 3 para generar una salida de tipo cuboidea.
- La función de activación bajo el capó es ReLU (unidad lineal rectificadora (ReLU) “es una función de activación que introduce la propiedad de no linealidad en un modelo de aprendizaje profundo y resuelve el problema de los gradientes de fuga) a excepción de la capa final, que utiliza una función de activación lineal” (Redmon & Farhadi, 2020).
- Algunas técnicas adicionales, como la normalización por lotes y el abandono, regularizan respectivamente el modelo y evitan que se sobreajuste.

2.4.2.2 Funcionamiento del modelo YOLO v4 para la detección de objetos

El enfoque principal del modelo YOLOv4 es enmarcar la detección de objetos mediante recuadros individuales, como se ilustra en la figura 17. El modelo funciona con base en los siguientes cuatro enfoques:

- 1) Bloques residuales.
- 2) Regresión de cuadro delimitador.
- 3) Intersección sobre uniones o IOU para abreviar.
- 4) Supresión no máxima.



Ilustración 16. (A) Imagen de entrada al modelo.




Ilustración 17. (B) Resultado del modelo YOLOv4.

Fuente: Elaboración propia.

a) Bloques residuales

En primera instancia, el modelo comienza dividiendo la imagen original (A) en celdas de cuadrícula $N \times N$ ($N=4$). Cada celda de la cuadrícula es responsable de localizar y predecir la clase del objeto que cubre, junto con el valor de probabilidad/confianza.



Ilustración 18. (A) Imagen de entrada al modelo.




Ilustración 19. (B) Bloques residuales del modelo.

Funcionamiento de la etapa bloques residuales del modelo YOLO.

Fuente: Elaboración propia.

b) Regresión de cuadro delimitador

Posteriormente, es necesario determinar los cuadros delimitadores que corresponden a rectángulos que resaltan todos los objetos de la imagen. Es posible generar tantos cuadros delimitadores como objetos haya dentro de una imagen dada.

YOLO determina los atributos de estos cuadros delimitadores utilizando un único módulo de regresión en el siguiente formato, donde la función $f(y)$ es la representación vectorial final para cada cuadro delimitador (DECI, 2023).

Ecuación 1. Representación vectorial para cuadros delimitadores.

$$f(y) = [pc, bx, by, bh, bw, c1, c2] \quad (1)$$

Cada cuadro delimitador contiene 5 valores adicionales además de las probabilidades de clase que son las siguientes:

- **Pc**: puntuación de confianza de que un objeto está presente en el cuadro delimitador.

Estos valores son especialmente importantes durante la fase de entrenamiento del modelo. Por ejemplo, todas las cuadrículas en negro tendrán una puntuación de probabilidad superior a cero y todas las cuadrículas en amarillo tendrán una puntuación de probabilidad igual a cero. La imagen de la derecha es la versión simplificada.




Ilustración 20. (A) Probabilidad de puntuación.



Ilustración 21. (B) Resultado de puntuación.

Funcionamiento de la etapa regresión de cuadro delimitador del modelo YOLO (A y B).

Fuente: Elaboración propia.

- **(bx, by)**: coordenadas del centro del objeto presente si lo hay. Este valor es "descartable" si no hay ningún objeto presente.
- **(bh, bw)**: alto y ancho del objeto presente. Este valor es "descartable" si no hay ningún objeto presente.
- **C**: clase del objeto que se detecta.

c) Intersección sobre uniones o IOU


Frecuentemente, un solo objeto presente en una imagen puede tener varios candidatos de cuadrículas para su predicción, aunque no todos sean relevantes. El objetivo

de la Intersección sobre uniones (IOU) (un valor entre 0 y 1) es descartar dichos cuadros de cuadrícula para conservar solo los relevantes al tipo de clase seleccionado, en nuestro caso automóviles y personas.

- Se deberá definir el umbral de selección de IOU, a un valor predeterminado, por ejemplo, 0,5.
- Posteriormente, el modelo YOLO calcula el IOU de cada celda de la cuadrícula, refiriendo el área de intersección dividida por el área de unión.
- Finalmente, ignora la predicción de las celdas de cuadrícula que tienen un umbral de $IOU \leq$ y considerando aquellas con un umbral de $IOU >$.

A continuación, se muestra una serie de ilustraciones del proceso de selección de cuadrícula al objeto sujeto. Podemos observar que el objeto originalmente tenía dos cuadrículas candidatas, descartando la cuadrícula 2.

$$IOU = \text{Área de intersección} / \text{Unión}$$



*Ilustración 22. Funcionamiento de la etapa bloques residuales del modelo YOLO IOU.
Fuente: Elaboración propia.*

(B) Umbral de selección de IOU




Ilustración 23. Funcionamiento de la etapa bloques residuales del modelo YOLO umbral de selección.
Fuente: Elaboración propia.





Ilustración 24. Funcionamiento de la etapa bloques residuales del modelo YOLO selección de cuadrícula.
Fuente: Elaboración propia.

(C) Cuadrícula seleccionada



*Ilustración 25. Funcionamiento de la etapa bloques residuales del modelo YOLO cuadro delimitador.
Fuente: Elaboración propia.*

d) Supresión no máxima (NMS)

Ocasionalmente debido a que un objeto puede tener varios cuadros con IOU más allá del umbral (P_c), es necesario implementar la supresión no máxima (NMS) para mantener solo las casillas con la puntuación de probabilidad más alta de detección.

2.4.2.3 Limitaciones de YOLOv4 en la detección de vehículos

Considerando que el objetivo principal de esta aplicación es su implementación mediante un prototipo funcional se optó por usar la versión YOLO Tiny v4. Al aplicar el modelo YOLOv4 para la detección de vehículos, es necesario tomar en consideración el rendimiento limitado del hardware de los dispositivos a utilizar. El modelo YOLOv4 no es lo suficientemente compacto para ejecutarse en dispositivos integrados como LattePanda, Jetson Nano, entre otras. Para la detección de objetos en tiempo real, YOLOv4-tiny representa una mejor opción en comparación con YOLOv4, debido a que su arquitectura se centra en mejorar

el tiempo de inferencia, por lo cual, es ideal para utilizar en un entorno de detección de objetos en tiempo real.




Ilustración 26. Comparativo de velocidad y precisión de YOLO v4.

Fuente: Bochkovskiy, A., Wang, C.-Y., & Liao, H.-y. (s.f.). *YOLOv4: Optimal Speed and Accuracy of Object Detection*.

La ilustración 26 compara la precisión promedio (AP: Average Precision por sus siglas en inglés) sobre los fotogramas por segundo (FPS) para varios modelos, incluidos YOLOv4 y YOLOv4-tiny. El gráfico describe cómo YOLOv4 superó a YOLOv4-tiny en términos de precisión, aunque tuvo un rendimiento muy inferior en términos de rendimiento computacional. YOLOv4-tiny se desarrolló originalmente para funcionar bien en sistemas integrados de bajo costo, para realizar tareas básicas de visión por computadora.

El tamaño pequeño del modelo menor a 50 MB y la velocidad de inferencia rápida, hacen que el modelo YOLO Tiny v4 sea adecuado para dispositivos integrados de visión por computadora como Raspberry Pi y/o NVIDIA Jetson Nano, por lo cual es el que se emplea en las pruebas de campo.

2.4.3 Modelado del programa para la detección de vehículos en Python

Una vez elegido el modelo YOLO Tiny v4 y el hardware a utilizar se procedió al modelado del programa en Python. A continuación, se utilizaron las siguientes librerías (módulos) dentro del programa para el procesamiento de las imágenes almacenadas.

OpenCV (cv2)

La detección y el seguimiento de objetos son tareas críticas en el presente caso de estudio y OpenCV es una herramienta idónea para implementar estas tareas. OpenCV es una biblioteca de software de aprendizaje automático y visión por computadora de código abierto. OpenCV se creó para proporcionar una infraestructura común para aplicaciones de visión por computadora, acelerando su implementación y desarrollo. Su capacidad para manejar múltiples formatos de imagen y video, junto con sus avanzadas funciones de procesamiento de imágenes, la hacen ideal. En este desarrollo, OpenCV se emplea para la captura y procesamiento de imágenes y videos, así como para la detección de objetos en tiempo real (OpenCV Org., 2024). Las funcionalidades específicas de OpenCV utilizadas en este proyecto incluyen la lectura de videos desde múltiples cámaras, la detección de objetos utilizando el modelo YOLO (You Only Look Once), y el cálculo de distancias a los objetos detectados mediante técnicas de triangulación.

Pygame

Es una biblioteca de Python diseñada para el desarrollo de videojuegos, proporcionando capacidades para manejar gráficos, sonido y eventos de entrada del usuario. Pygame también incluye soporte para reproducir y manipular sonidos, lo que facilita la adición de efectos sonoros a los desarrollos (Pygame Org., 2022). Admite soporte para formatos de archivos WAV, MP3 y OGG. En este desarrollo, Pygame se utiliza para reproducir sonidos de alerta cuando se detectan objetos a una distancia peligrosa, mejorando así la interacción del usuario con el sistema de monitoreo. Pygame permite cargar y reproducir archivos de sonido de manera

eficiente, y su capacidad para manejar múltiples canales de audio facilita la implementación de alertas sonoras en tiempo real.

Tkinter

Es una biblioteca estándar de Python para la creación de interfaces gráficas de usuario. Tkinter es un paquete implementado en C que agrega comandos personalizados para crear y manipular widgets en la interfaz de usuario (McGill CS, 2022). Esta librería se utilizó para para construir la interfaz principal que muestra los videos de las cámaras, botones de alerta y otros elementos interactivos permitiendo una interacción intuitiva y visualmente accesible para los usuarios. Además, su integración con PIL permite la visualización de imágenes procesadas en tiempo real.

Python Imaging Library (PIL)

Es una biblioteca de procesamiento de imágenes en Python que permite abrir, manipular y guardar archivos de imagen en diversos formatos. Esta biblioteca está diseñada para un acceso rápido a los datos almacenados en formatos de píxeles básicos. La biblioteca contiene funciones básicas de procesamiento, incluidas operaciones puntuales, filtrado con un conjunto de núcleos de convolución incorporados y conversiones de espacio de color. En este proyecto, PIL se utiliza para la manipulación y visualización de imágenes dentro de la interfaz Tkinter, facilitando la integración de elementos gráficos como logotipos y fotos capturadas (Python Pillow Org., 2023).

2.4.3.1 Configuración del programa para la detección de vehículos en Python

1) Inicialización de Librerías

Una vez inicializado el programa se importarán las librerías y módulos necesarios:

- OpenCV (cv2) librería utilizada para el manejo de modelos de aprendizaje automático y el procesamiento de imágenes y video.
- Los módulos Image e ImageTk de la librería PIL para el procesamiento y manipulación de imágenes a diferentes formatos compatibles con la interfaz de usuario.

- Librería Tkinter para el desarrollo de la interfaz gráfica de usuario en el lenguaje Python.
- Librería Pygame utilizada para la alerta sonora.

2) Inicialización de Parámetros y Variables globales

Posteriormente, se definen los valores de las variables globales y constantes. Las constantes que se definieron fueron las siguientes: Distancia_conocida (representa la distancia conocida entre la cámara y el objeto durante la calibración.) con un valor de 48 centímetros, Ancho_persona (representa el ancho real conocido de una persona), con un valor de 35 centímetros, Ancho_vehículo (representa el ancho conocido de un automóvil) con un valor de 180 centímetros, y Distancia_alerta (representa la distancia a la que se debe activar una alerta) con diferentes valores preestablecidos en dependencia de la zona de riesgo.

3) Configuración de la Interfaz Gráfica

Se configura la ventana principal de la aplicación mediante la librería Tkinter, asignándole un título y tamaño. Se crean dos botones ("Encender" y "Salir") con etiquetas, comandos y estilos de fuente específicos. Luego, los botones se colocan dentro de la ventana de la aplicación utilizando el método de ubicación.

4) Función on_submit

Una vez que el usuario interactúe con el botón de Encender se corre la función on_submit(). Esta función coordina la inicialización del modelo de detección de objetos, la configuración de las cámaras, la actualización de la interfaz gráfica, la lógica de detección y las alertas en tiempo real.

5) Carga del Modelo YOLO:

La función `yoloNet = cv2.dnn.readNet('yolov4-tiny.weights', 'yolov4-tiny.cfg')` carga el modelo YOLO previamente entrenado utilizando los pesos y el archivo de configuración. El archivo binario contiene los pesos entrenados y el archivo de texto contiene la configuración

de la red. La función ReadNet se encarga de analizar la red de aprendizaje profundo representada en los formatos admitidos.

6) Carga de Clases de Objetos a Detectar

Se calibran las cámaras cargando una imagen de una persona predefinida que previamente fue tomada con las cámaras, con la finalidad de obtener la medición del ancho de la persona, utilizando el modelo YOLO tiny v4 se realiza la detección. Este proceso es crucial para convertir la distancia referenciada en píxeles del objeto a una distancia en metros de forma más precisa. El mismo proceso se realiza para la calibración de la detección de vehículos.

7) Inicialización de Capturas de Cámaras

Utilizando la librería cv2 se establecen tres variables globales para capturar el video de entrada en las 3 cámaras: capture1, ..., capture3. Cada 200 milisegundos las cámaras toman una imagen usando el método read() de las cámaras capture1, capture2 y capture3.

8) Función de Detección de Objetos

La función detect_object(object, model, class_names), recibe las capturas de la cámara como entrada y utiliza el modelo YOLO Tiny v4 previamente entrenado para detectar objetos en la imagen. Esta función devuelve una lista con la información del objeto. Si se detecta una persona o un vehículo, se dibuja un rectángulo alrededor del objeto.

9) Función de Cálculo de Distancia y de Longitud Focal

Si se detecta un objeto en la captura de las cámaras, se calcula la distancia con la función cal_distance(f, W, w), que calcula la distancia a un objeto utilizando la distancia focal, el ancho conocido y el ancho real del objeto.

10) Función de Actualización del Color del Botón de Alerta

La función update_button_color(distance, alert_button) compara el valor de la distancia y, dependiendo del valor, actualiza el botón de alerta para mostrar el color definido correspondiente a cada una de las cámaras.

11) Función de Finalización del Programa

Se crea la función `exit_program()`, que permite salir del programa con un boton. Esta función libera las cámaras y cierra la interfaz.

En resumen, el código combina técnicas de visión por computadora con una interfaz gráfica de usuario creando un sistema de medición de distancias de objetos en tiempo real. Captura video de múltiples cámaras, y utilizando el modelo YOLO tiny v4 previamente entrenado para detectar objetos, calcula distancias y proporciona una interfaz fácil de usar para monitorear y controlar el sistema. El diagrama de flujo siguiente es la representación gráfica del proceso de trabajo del programa para la detección de objetos en Python. Las características antes representadas se pueden observar en la figura 27.

2.4.3.2 Diagrama de flujo del programa desarrollado en Python

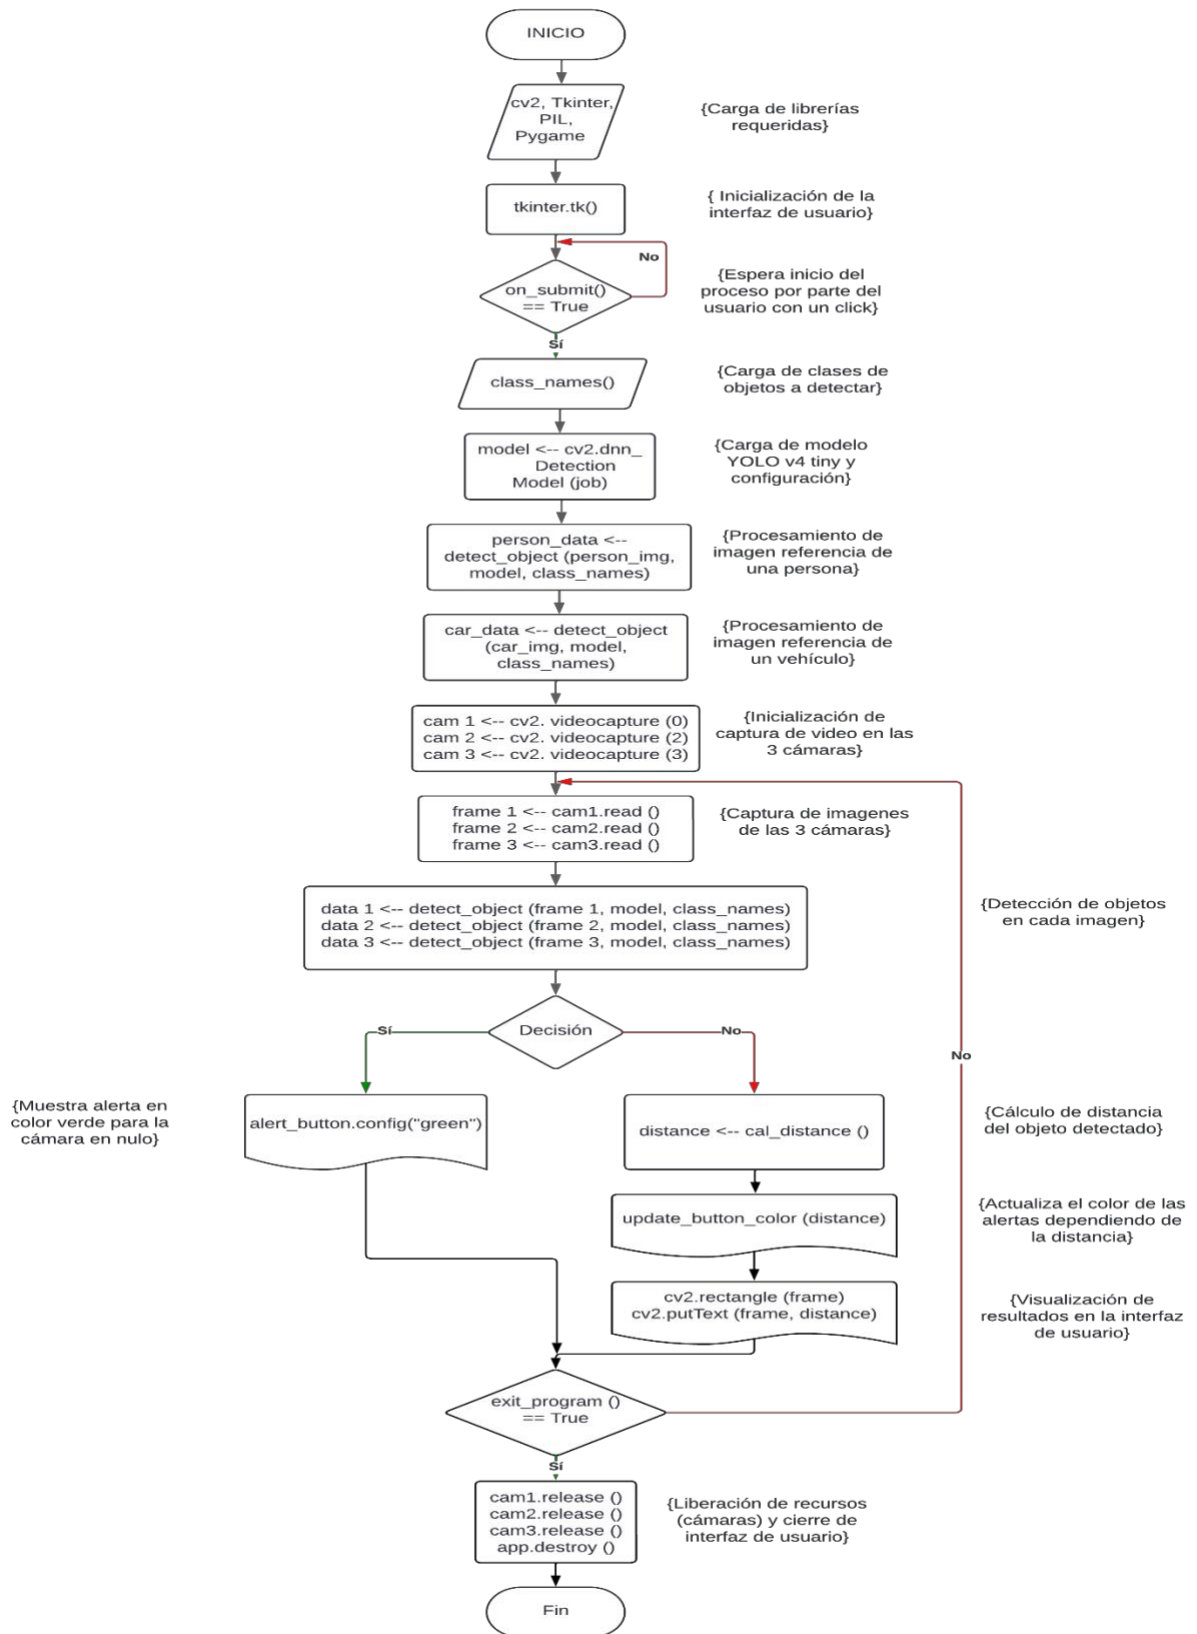


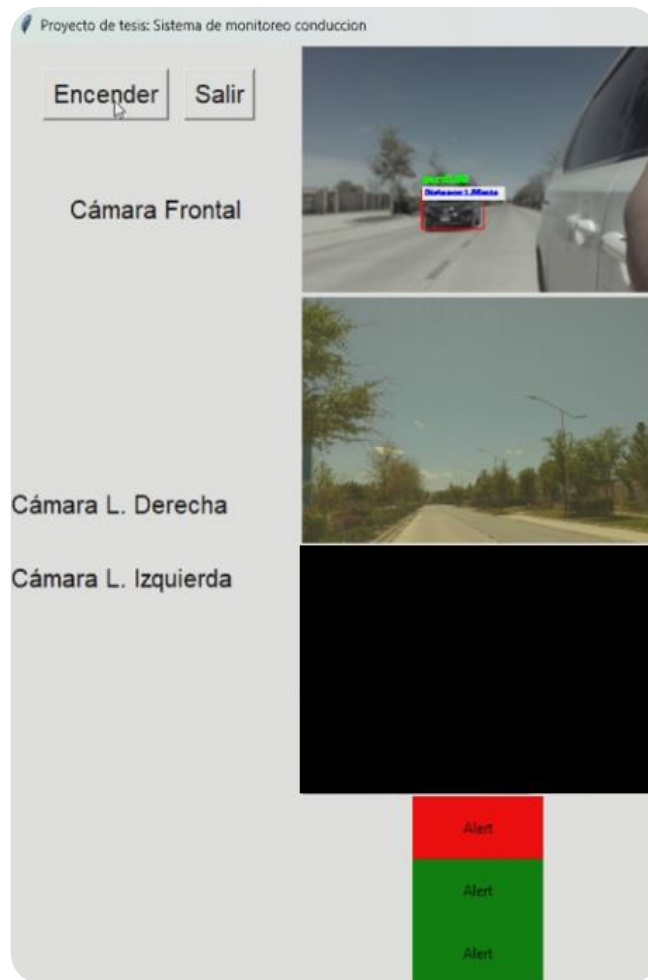
Ilustración 27. Diagrama de flujo del programa para la detección de objetos en Python.
Fuente: Elaboración propia.

Como se mencionó anteriormente, el desarrollo del sistema consiste en las siguientes secciones:

- Captación de las imágenes tomadas mediante las cámaras Logitech 920s y Brio 100.
- Procesamiento de los archivos capturados.
- Cálculo de la distancia y zona de riesgo.
- Emisión de alerta audiovisual.

2.4.3.3 Interfaz de usuario e iniciación de cámaras en Python

La interfaz de usuario (IU) está representada mediante un diseño simple y estructurado, con la finalidad de generar una interacción sencilla con los futuros usuarios del prototipo. La IU consiste en un grupo de botones en la parte superior, donde se observan dos botones para su iniciación y finalización como se observa en la figura 28. Posteriormente, se encuentra los indicadores gráficos de las imágenes/video capturadas en tiempo real siendo analizadas continuamente. Como se mencionó, el sistema debe ser capaz de emitir alertas audiovisuales, por lo cual, se añadieron tres indicadores tipo LED en color verde y la emisión sonora mediante las bocinas del dispositivo.



*Ilustración 28. Interfaz de usuario mediante Python.
Fuente: Elaboración propia.*

2.4.3.4 Captación de video en tiempo real

Posteriormente, será necesario la adquisición continua de imágenes/video. Se configuró el procesamiento en modo adquisición en línea con gestión continua. Con la finalidad de evitar la pérdida de imágenes se especificó el número de archivos para almacenar en el búfer.



*Ilustración 29. Configuración de la adquisición en tiempo real.
Fuente: Elaboración propia.*

2.4.4 Posicionamiento de las cámaras en el vehículo (pruebas de campo)

Previo al comienzo del sistema, las cámaras se deberán posicionar tomando como referencia las siguientes consideraciones:

Cómo se observa en la figura 30, se realizó el posicionamiento de las cámaras en los pilares A, a una altura de 1.5 metros con referencia al piso del vehículo sujeto para el sistema de detección de punto ciego (BSD).



*Ilustración 30. Configuración de la cámara lateral centrada en el pilar A del lado del conductor.
Fuente: KIA. (2018). Sorento Showroom.*

Para el sistema de detección de colisión frontal (FCW) se decidió posicionar sobre el parabrisas frontal a una altura de 60 centímetros con referencia al tablero del vehículo sujeto como se aprecia en la siguiente figura 31.



*Ilustración 31. Configuración de la cámara frontal centrada en el parabrisas frontal.
Fuente: KIA. (2018). Sorento Showroom.*

Habiendo analizado el sistema se procedió a la realización de las pruebas de campo mediante el equipo Lenovo Ideapad, tomando como referencia la planeación y configuración previamente delineadas.

2.4.4.1 Cálculo de la distancia y longitud focal

Las funciones `cal_distance` y `cal_focalLength` se utilizan para realizar cálculos relacionados con la distancia entre la cámara y un objeto detectado, así como la distancia focal de la cámara. Estas funciones se basan en la ecuación de lentes convexas y cóncavas y son esenciales para la estimación precisa de distancias en un sistema de visión por computadora (Hoang, 2023).

La función “`cal_distance`” calcula la distancia entre la cámara y un objeto en función de la distancia focal (f), la altura conocida del objeto (W), y la altura del objeto en píxeles (w). La ecuación utilizada para el cálculo es:

Ecuación 2. Distancia en metros hacia un objeto.

$$distancia = \frac{w \cdot f}{W} \quad (2)$$

- f : Distancia focal de la cámara.
- W : La altura conocida del objeto en la realidad (centímetros).
- w : La altura del objeto detectado en píxeles en la imagen.

En este caso, se está calculando la distancia a un objeto (ya sea una persona o un automóvil) utilizando la distancia focal específica para la detección de personas o vehículos (focal_person, focal_car), el ancho conocido del objeto (person_width), y el ancho del objeto en píxeles.

La función “cal_focalLength” calcula la distancia focal de la cámara en función de la distancia al objeto (d), el ancho conocido del objeto (W), y el ancho del objeto en píxeles (w) utilizando una imagen de referencia donde se conoce la distancia real al objeto y las dimensiones reales del objeto.

La ecuación utilizada para el cálculo es:

Ecuación 3. Distancia focal de la cámara en función de la distancia al objeto.

$$distancia\ focal = \frac{W \cdot d}{2 \cdot w} \quad (3)$$

d: La distancia conocida entre la cámara y el objeto en la imagen de referencia (en centímetros).

W: El ancho conocido del objeto en la realidad (en centímetros).

w: El ancho del objeto en píxeles en la imagen.

Además, se calcula la distancia focal específica para la detección de personas o vehículos utilizando la distancia conocida, el ancho conocido del objeto y el ancho del objeto en píxeles. Este valor se utiliza posteriormente para calcular la distancia a los objetos detectados en tiempo real.

A continuación, se muestra un ejemplo del cálculo de una distancia con valores predeterminados para la cámara utilizada Logitech c920, la cual captura video en una resolución 1920x1080, con una longitud focal preestablecida de 3.67 mm y un sensor con tamaño de 16/2.88 y alturas predeterminadas.

- Resolución (píxeles): 1920x1080
- Longitud focal (milímetros): 3.67
- Tamaño de píxel (µm): 3.98

- Tamaño del sensor (pulgadas): 16/2.88
- Altura real del objeto (milímetros): 180
- Altura de la imagen del objeto (píxeles): 370

$$distancia = \frac{(3.67 \text{ mm})(180 \text{ mm})(1080 \text{ px})}{511 \text{ px}} \cdot \frac{(1 \text{ in})}{2.88 \text{ in}} \cdot \left(\frac{2.54 \text{ mm}}{1 \text{ in}}\right) \quad (2)$$

$$distancia = 513 \text{ mm}$$

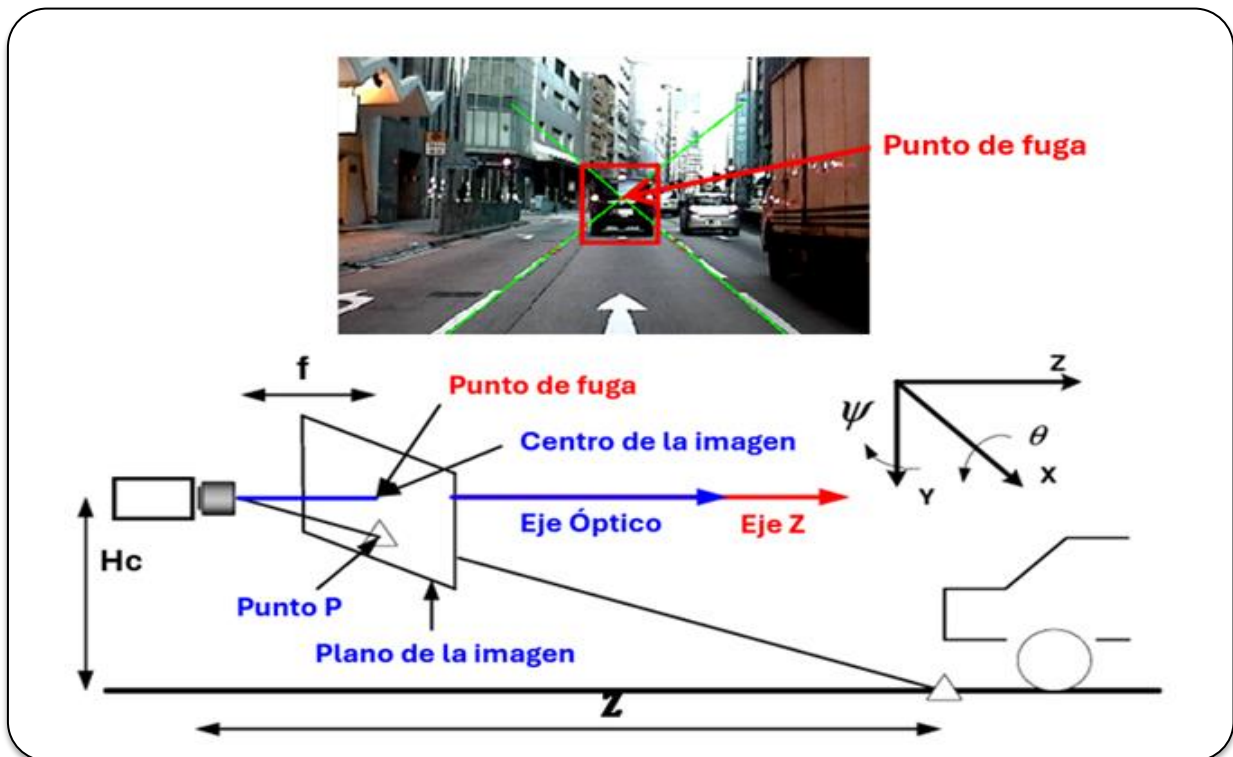


Ilustración 32. Configuración punto y distancia focal.

Fuente: Cheung, H., Siu, W., Lee, S., Poon, L., & Ng, C. (2012). *Accurate distance estimation using camera orientation compensation technique for vehicle driver assistance system.*

Como se puede observar en la Ilustración 32, los sistemas de reconocimiento de vehículos buscan los autos precedentes y dibujan un cuadro delimitador que circunscribe cada vehículo detectado. En segundo lugar, el sistema de reconocimiento de puntos de fuga reconoce el carril y calcula el punto de fuga. Posteriormente, se toma una muestra de las coordenadas de un punto (Punto P) en la línea inferior del cuadro delimitador y se calcula la distancia del vehículo anterior desde el centro óptico de la cámara, Z. Para el caso ideal, tenemos el eje óptico del cámara paralelo al eje Z, que es paralelo a la superficie de la carretera, como se

muestra en la ilustración referenciada. Mediante la calibración de la cámara, podemos calcular los valores de la altura de la cámara desde el suelo, H_c (Altura conocida), en metros y la distancia focal , f , en píxeles. La distancia del vehículo precedente, Z , se puede calcular utilizando las ecuaciones antes mencionadas.

Habiendo analizado el sistema se procedió a la determinación preliminar del número de pruebas requeridas para evaluar el prototipo de sistema, tomando como referencia la planeación y configuración previamente delineadas.

III. PROCEDIMIENTO EXPERIMENTAL

3.1 Procedimiento Experimental

3.1.1 *Desarrollo de pruebas de campo para BSD mediante Lenovo Ideapad y Delta LattePanda 3*

Al inicio de la prueba el vehículo sujeto y el vehículo objetivo se condujeron tomando las consideraciones establecidas, en carriles alternos, pero en paralelo, con el vehículo objetivo rebasando longitudinalmente al vehículo sujeto. El vehículo objetivo paso en el carril junto al vehículo sujeto, por ambos los lados subyacentes.



Ilustración 33. Vehículo objetivo adelantando al vehículo sujeto por ambos carriles.

Fuente: Elaboración propia.

Como ya se mencionó en las configuraciones de las pruebas, el escenario de prueba en línea recta para BSD se llevó a cabo bajo las siguientes consideraciones:

- En un camino recto controlado, el cual contuvo dos carriles.
- Conducción paralela en pavimento seco y sin irregularidades.
- La prueba se realizó durante el día.

Se recopilaron las muestras de las repeticiones realizadas en cada zona de alerta y por cada prototipo de prueba utilizado (Lenovo Ideapad y LattePanda Delta), además por lado (piloto y copiloto) para determinar la tasa de éxito global, general y particulares.



*Ilustración 34. Vehículo objetivo entrando en una zona de 5 metros con velocidad objetivo.
Fuente: Elaboración propia.*

3.1.1.1 Muestras de resultados obtenidos en las pruebas BSD

Se realizaron pruebas por cada zona de riesgo, observando cada alerta para BSD, logrando de igual forma almacenar en el directorio establecido las imágenes procesadas en la computadora. Se realizó el cálculo del tamaño de muestra mediante valores planificados después de una extensa investigación y búsquedas relacionadas al diseño del sistema, la verificación de esta se ilustra en la siguiente sección del caso de estudio.

3.1.1.1.1 Pruebas BSD (lado piloto)

En las siguientes tablas 4 - 6, se ilustra una muestra representativa de las pruebas realizadas en campo para BSD (lado piloto) en cada una de sus zonas de riesgo. Dentro de las tablas se definen las imágenes previas al procesamiento y posprocesamiento de este.

Tabla 3. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona crítica.







Zona crítica (rojo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			Sí
N° Total de pruebas realizadas: 370			

Tabla 4. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona precautoria.






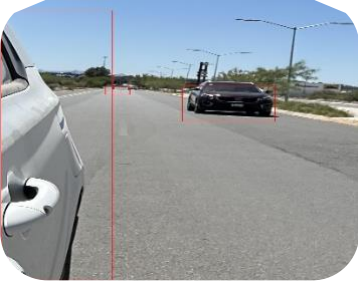



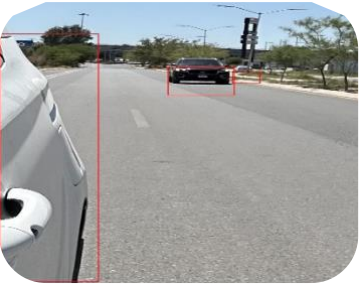


Zona precautoria (amarillo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			Sí
N° Total de pruebas realizadas: 370			

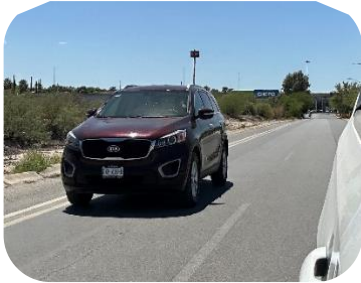
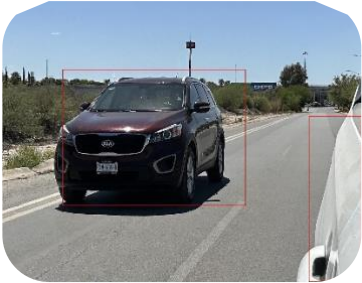



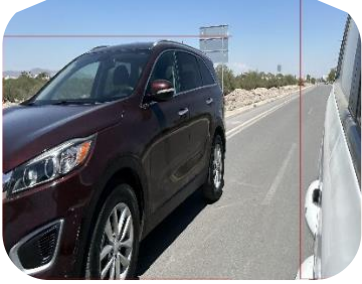
Tabla 5. Muestra de pruebas realizadas en campo para BSD (lado piloto) zona riesgo bajo.

Zona riesgo bajo (azul)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			Sí
N° Total de pruebas realizadas: 250			

3.1.1.1.2 Pruebas BSD (lado copiloto)

En las siguientes tablas 7 – 9, se ilustra una muestra representativa de las pruebas realizadas en campo para BSD (lado copiloto) en cada una de sus zonas de riesgo. Dentro de las tablas se definen las imágenes previas al preprocesamiento y posprocesamiento de este.

Tabla 6. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona crítica.

Zona crítica (rojo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			Sí

Nº Total de pruebas realizadas: 370

Tabla 7. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona precautoria.


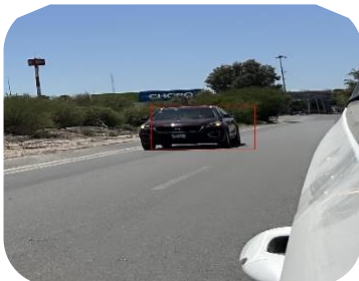










Zona precautoria (amarillo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			Sí
N° Total de pruebas realizadas: 370			

Tabla 8. Muestra de pruebas realizadas en campo para BSD (lado copiloto) zona riesgo bajo.

Zona riesgo bajo (azul)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			No
Prueba 3			Sí
Nº Total de pruebas realizadas: 250			

3.1.2 *Desarrollo de pruebas de campo para FCW mediante Lenovo Ideapad y Delta LattePanda 3*

Al inicio de la prueba el vehículo sujeto y el vehículo objetivo se condujeron tomando las consideraciones establecidas, en el mismo carril, pero a una distancia longitudinal de +10 metros, con el vehículo objetivo. El vehículo objetivo paso a descender su velocidad de manera constante, el vehículo sujeto se aproximó una distancia menor a los 10 metros iniciales por la parte trasera del vehículo objetivo.



Ilustración 35. Vehículo sujeto aproximándose al vehículo objetivo.

Fuente: Elaboración propia.

Como ya se mencionó en las configuraciones de las pruebas. El escenario de prueba en línea recta para FCW se llevó a cabo bajo las siguientes consideraciones:

- En un camino recto controlado, el cual contuvo dos carriles.
- Conducción paralela en pavimento seco y sin irregularidades.
- La prueba se realizó durante el día.

Se recopilaron las muestras de las repeticiones realizadas de cada zona de alerta y por cada prototipo de prueba utilizado (Lenovo Ideapad y LattePanda Delta), para determinar la tasa de éxito global, general y particulares en la siguiente sección.









Ilustración 36. Vehículo objetivo entrando en una zona de 10 metros con velocidad objetivo.

Fuente: Elaboración propia.

3.1.2.1 Muestras de resultados obtenidos en las pruebas FCW

En las siguientes tablas 10 – 12, se ilustra una muestra representativa de las pruebas realizadas en campo para FCW (frontal) en cada una de sus zonas de riesgo. Dentro de la tabla se definen las imágenes previas al preprocesamiento y posprocesamiento de este. Se realizó el cálculo del tamaño de muestra mediante valores planificados después de una extensa investigación y búsquedas relacionadas al diseño del sistema, la verificación de esta se ilustra en la siguiente sección del caso de estudio.

Tabla 9. Muestra de pruebas realizadas en campo para FCW (frontal) zona crítica.

Zona crítica (rojo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			No
Prueba 2			Sí
Prueba 3			Sí

Nº Total de pruebas realizadas: 370

Tabla 10. Muestra de pruebas realizadas en campo para FCW (frontal) zona precautoria.













Zona precautoria (amarillo)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			Sí
Prueba 2			Sí
Prueba 3			No
N° Total de pruebas realizadas: 370			

Tabla 11. Muestra de pruebas realizadas en campo para FCW (frontal) zona riesgo bajo.

Zona riesgo bajo (azul)	Imagen preprocesamiento	Imagen posprocesamiento	¿Detección realizada?
Prueba 1			No
Prueba 2			Sí
Prueba 3			No

N° Total de pruebas realizadas: 250

Habiendo realizado las pruebas de campo en su totalidad para todas las zonas de riesgo estudiadas, se procederá al análisis de resultados. Teniendo como referencias los objetivos específicos delimitados en el capítulo 1.

IV. DISEÑO ESTADÍSTICO INFERENCIAL

Estamos interesados en tomar una decisión en torno a la veracidad o falsedad de la hipótesis establecida en el capítulo 1. El procedimiento que conduce a tomar tal decisión es la prueba de esta misma. Los procedimientos de la prueba de hipótesis dependen del uso de la información en una muestra aleatoria de la población de interés. Si esta información es consistente con la hipótesis, entonces concluiríamos que la hipótesis es verdadera; sin embargo, si esta información es inconsistente con la hipótesis, concluiríamos que esta es falsa. Para probar una hipótesis, debemos tomar una muestra al azar, calcular una estadística de prueba apropiada a partir de los datos de la muestra, y después utilizar la información contenida en esta estadística de prueba para tomar una decisión relacionado al rechazo, o bien, no rechazo de la hipótesis (Hines & Montgomery, 1996).

Cuando se toma una decisión utilizando la información en una muestra aleatoria, esta decisión está sujeta a error. Pueden producirse dos tipos de errores cuando se prueban hipótesis. Si la hipótesis nula H_0 se rechaza cuando es verdadera, entonces se ha cometido un error del tipo I. Si la hipótesis nula H_0 se acepta cuando es falsa, entonces el error cometido es del tipo II (Hines & Montgomery, 1996). Esta situación se describe en la tabla 3.

Tabla 12. Decisiones en la prueba de hipótesis

	Ho es verdadera	Ho es falsa
Aceptación de H_0	Ningún error	Error del tipo II β : Probabilidad de cometer el error tipo II.
Rechazo de H_0	Error del tipo I α : Probabilidad de cometer el Error tipo I.	Ningún error

En las siguientes secciones del capítulo se desarrolla el diseño y la metodología del experimento estadístico que guio la determinación del número de pruebas requerido

considerando los valores de probabilidad de α y β admitidos así como la proporción de comparación p_1 planeada. Se espera que el diseño y metodología para los experimentos estadísticos contribuyan tanto a la validez de las pruebas de campo como a una estimación confiable de los parámetros tasa de éxitos (p) y fiabilidad o probabilidad de no falla (p_s) como características fundamentales de diseño del prototipo creado.

Para realizar la inferencia estadística completa del sistema bajo estudio, es necesario desarrollar de modo integral, para cada una de las hipótesis formuladas en los Objetivos específicos de investigación (sección , cada uno de sus tres componentes, a saber:

- Determinación del tamaño y la potencia de la muestra que se empleará en cada contraste de hipótesis.
- Efectuar las Pruebas de hipótesis respecto a la tasa de éxito del sistema de advertencia de cambio de carril y de advertencia de colisión frontal.
- Evaluación de la tasa de éxito esperada a nivel poblacional del prototipo bajo estudio mediante la determinación del intervalo de confianza de $100(1 - \alpha)\%$ para p .

En el presente capítulo mediante el método de Prueba de hipótesis se prueba la hipótesis global de investigación que se encuentra en el apartado 1.1.3.3. y la cual se estableció a manera de hipótesis nula, a saber

$H_0: p \geq 0.93$ La tasa global de éxitos del prototipo de sistema de advertencia es por lo menos de 93%.

Así mismo, en este capítulo se prueban las hipótesis planteadas en el apartado 1.1.3.5. Se decidió plantear los objetivos específicos y las hipótesis de cada uno de ellos, en casos enumerados del 1 al 6 para una mayor facilidad.

Caso 1

1. Estimar la tasa general de éxito del prototipo del sistema de advertencia de detección de posibles eventos de punto ciego y frontal con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.

1) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo ante eventos de posible colisión frontal y punto ciego es mayor o igual a 93%.

Caso 2

2. Estimar la tasa general de éxito del prototipo de sistema del sistema de advertencia de detección de posibles eventos de punto ciego y frontal con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.

2) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Latte ante eventos de posible colisión frontal y punto ciego es por lo menos de 93%.

Caso 3

3. Estimar la tasa particular de éxito con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto del sistema de advertencia de colisión frontal, la cual debe ser al menos de 93%.

3) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.

Caso 4

4. Estimar la tasa particular de éxito con equipo Lenovo Ideapad en tres niveles: bajo, medio y alto del sistema de advertencia de detección de punto ciego, la cual debe ser al menos de 93%.

4) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de detección de punto ciego es por lo menos de 93%.

Caso 5

5. Estimar la tasa de particular de éxito con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto del sistema de advertencia de colisión frontal, la cual debe ser al menos de 93%.

5) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.

Caso 6

6. Estimar la tasa de éxito del prototipo del sistema de advertencia de detección de punto ciego con equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto, la cual debe ser al menos de 93%.

6) $H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de detección de punto ciego es por lo menos de 93%.

4.1 Contraste de hipótesis para probar: La tasa global de éxito del prototipo

Éxito: se refiere a que durante el desarrollo de las pruebas de campo, el prototipo emita, una alerta frente a eventos de posible colisión.

Fracaso: se refiere a aquellos resultados que podemos considerar como falsos negativos e incluso, si los hubiere, falsos positivos.

Global: significa que incluye el total de pruebas punto ciego y frontales realizadas y tanto con el equipo Lenovo Ideapad como con el equipo LattePanda Delta 3.

$H_0: p \geq 0.93$ La proporción global de éxitos (p) del dispositivo es de 93%

$H_1: p < 0.93$ La proporción de éxitos (p) del dispositivo es menor de 93%

$\alpha = 0.05$ ¹ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.05$ es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Ecuación 4. Expresión de la potencia de la muestra.

$$\text{Potencia} = 1 - \beta \quad (4)$$

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor de probabilidad admitido para β se obtiene el valor de potencia deseado, si por ejemplo se acepta que $\beta = 0.05$, se tiene

$$\text{Potencia} = 1 - 0.05 = 0.95$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia elegido, igual o mayor al valor de p en H_0 , en este caso de 0.93. En una sección posterior, mediante la estimación del intervalo de confianza de $(1 - \alpha)100\%$, se determina el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión. La tasa de éxito poblacional p , es un parámetro en el que X , el número de éxitos en la muestra sigue una distribución de probabilidad binomial².

Cuando se utiliza el método de Prueba de hipótesis, se pueden cometer dos tipos de error, Error tipo I y Error tipo II, la cuestión es que la probabilidad de cometerlos sea razonablemente baja. El control de ambos tipos de error se lleva a cabo al determinar la potencia de la muestra empleada. Si bien el valor aceptado de α (la probabilidad de cometer

¹ Asignar a α el valor de probabilidad 0.05 es muy común debido a que, por lo general, contribuye a generar un tamaño de muestra requerido equilibrado, esto porque n se relaciona en razón inversa con el valor de α .

² Conviene recordar los supuestos de la distribución binomial

- Se extrae una muestra aleatoria (de tamaño n) sin reemplazo a partir de una población infinita o con reemplazo a partir de una población finita.

- Cada resultado se puede clasificar en una de dos categorías mutuamente excluyentes y colectivamente exhaustivas: “éxito” o “fracaso”.

- Los resultados son independientes.

el error tipo I) es determinado por el investigador, también es cierto que el valor de α se relaciona en razón indirecta con el tamaño de muestra (n). Por lo tanto, es importante llevar a cabo una buena selección de los valores planificados de α y β , de lo contrario, quizá se obtendrían tamaños de muestras innecesariamente elevados con relación a la potencia proyectada o muy pequeños con una potencia exígua.

4.1.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas para cada atributo de interés (n) necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.1.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.000026$
- $Potencia = 1 - 0.000026 = 0.99997$
- $p_1 = 0.90$
- $n = ?$

4.1.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

Ecuación 5. Expresión de la potencia unilateral.

$$\text{Potencia} = \Phi \left(\frac{p_0 - p_1 - z_{\alpha} \sqrt{\frac{p_0 (1-p_0)}{n}}}{\sqrt{\frac{p_1 (1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.999974 = \Phi \left[\frac{(0.93 - 0.90) - z_{0.05} \sqrt{\frac{0.93 (1-0.93)}{n}}}{\sqrt{\frac{0.90 (1-0.90)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$:




Ilustración 37. Gráfica de la distribución normal estándar.

Fuente: Minitab 2018.

$$0.999974 = \Phi \left[\frac{(0.93 - 0.90) - 1.645 \sqrt{\frac{0.93 (1-0.93)}{n}}}{\sqrt{\frac{0.90 (1-0.90)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.999974.

Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 2970 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, *Potencia* = 0.999974 y con acuerdo a la ecuación 4: $\beta = 1 - 0.999974 = 0.000026$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.90$, se decidió realizar este estudio con un tamaño de muestra de 2,970 pruebas para, a continuación, probar la hipótesis general de investigación planteada en la sección 1.1.3.3, a saber:

$H_0: p \geq 0.93$ La proporción global de éxitos del prototipo es de 93% o mayor.

4.1.2 Prueba de hipótesis

4.1.2.1 Hipótesis estadísticas y nivel de significancia

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.1.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta evento de posible colisión/No detecta

Para $H_1: p < p_0$, el estadístico de prueba es:

Ecuación 6. Expresión del Valor p.

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

x : N° de éxitos en la muestra

n : Tamaño de la muestra o número de pruebas a realizar

p_0 : Probabilidad de éxito (valor de p en la H_0)

q : Probabilidad de fracaso

Ecuación 7. Expresión para la probabilidad de fracaso.

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

Ecuación 8. Expresión de la función de probabilidad binomial.

$$P[X = x] = \frac{n!}{x! (n - x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.1.2.3 Cálculo del estadístico de prueba

Datos muestrales:

- $x = 2,801$ Número de éxitos en las pruebas realizadas.
- $n = 2,970$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 2,801 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p = & \frac{2970!}{0!(2970-0)!} 0.93^0 0.07^{2970-0} + \frac{2970!}{1!(2970-1)!} 0.93^1 0.07^{2970-1} \\ & + \frac{2970!}{2!(2970-2)!} 0.93^2 0.07^{2970-2} + \dots \\ & + \frac{2970!}{2801!(2970-2801)!} 0.93^{2801} 0.07^{2970-2801} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 38. Gráfica de la distribución binomial para n (2970).

Fuente: Minitab 2018.

$$\text{Valor } p = 0.9981$$

4.1.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.1.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

Ecuación 9. Expresión del intervalo de confianza exacto de Clopper-Pearson.

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

- $x = 2801$ éxitos en la muestra
- $n = 2970$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (9):

$$p < \left[1 + \frac{2970 - 2801}{(2801 + 1)F_{0.05, 2(2801+1), 2(2970-2801)}} \right]^{-1}$$

$$p < \left[1 + \frac{169}{2801F_{0.05, 2(2801), 2(169)}} \right]^{-1}$$

$$p < \left[1 + \frac{169}{2801F_{0.05, 5602, 338}} \right]^{-1}$$




Ilustración 39. Gráfica de la distribución de F (5602,338).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{169}{2801(1.144)} \right]^{-1}$$

$$p < (1.0527409)^{-1}$$

$$p < 0.949901$$

Con un nivel de confianza de 95% el prototipo emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales tanto para FCW como de BSD con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites inferior de 90% y superior de 94.99%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.2 Caso 1: contraste de hipótesis para probar la tasa general de éxito del prototipo Lenovo Ideapad ante eventos de los sistemas FCW y BSD

General: Todas las pruebas realizadas para los sistemas de advertencia de colisión frontal y punto ciego con equipo Lenovo Ideapad.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad de los sistemas de advertencia de detección de colisión frontal y punto ciego es por lo menos de 93%.

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad de los sistemas de advertencia de detección de colisión frontal y punto ciego es menor de 93%.

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.05$, es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de $\beta = 0.000412$, se obtiene el valor de

$$\text{Potencia} = 1 - \beta \quad (4)$$

$$\text{Potencia} = 1 - 0.000412 = 0.999588$$

El interés una vez más se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

Cuando se utiliza el método de Prueba de hipótesis, se pueden cometer dos tipos de error, Error tipo I y Error tipo II, la cuestión es que la probabilidad de cometerlos sea razonablemente baja. El control de ambos tipos de error se lleva a cabo al determinar la potencia de la muestra empleada. Si bien el valor aceptado de α (la probabilidad de cometer el error tipo I) es determinado por el investigador, también es cierto que el valor de α se relaciona en razón indirecta con el tamaño de muestra (n). Por lo tanto, es importante llevar a cabo una buena selección de los valores planificados de α y β , de lo contrario, quizá se obtendrían tamaños de muestras innecesariamente elevados con relación a la potencia proyectada o muy pequeños con una potencia exigua.

4.2.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.2.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.000412$

- $Potencia = 1 - 0.000412 = 0.999588$
- $p_1 = 0.90$
- $n = ?$

4.2.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$Potencia = \Phi \left(\frac{p_0 - p_1 - z_{\alpha} \sqrt{\frac{p_0(1-p_0)}{n}}}{\sqrt{\frac{p_1(1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.999588 = \Phi \left[\frac{(0.93 - 0.90) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.90(1-0.90)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.999588 = \Phi \left[\frac{(0.93 - 0.90) - 1.645 \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.90(1-0.90)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.999588.

Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 2250 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la

labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, $Potencia = 0.999588$ y con acuerdo a la ecuación 4: $\beta = 1 - 0.999588 = 0.000412$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.90$, se decidió realizar este estudio con un tamaño de muestra de 2250 pruebas para, a continuación, probar la hipótesis referenciada con el número 1 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad de los sistemas de advertencia de detección de colisión frontal y punto ciego es por lo menos de 93%.

4.2.2 Prueba de hipótesis

4.2.2.1 Hipótesis estadística y nivel de significancia

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.2.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta vehículo/No detecta vehículo

Para $H_1: p < p_0$, el estadístico de prueba es:

$$Valor p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

- x : N° de éxitos en la muestra
- n : Tamaño de la muestra o número de pruebas a realizar
- p_0 : Probabilidad de éxito (valor de p en la H_0)
- q : Probabilidad de fracaso

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.2.2.3 Cálculo del estadístico de prueba

- $x = 2125$ Número de éxitos en las pruebas realizadas.
- $n = 2250$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 2125 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p = & \frac{2250!}{0!(2250-0)!} 0.93^0 0.07^{2250-0} + \frac{2250!}{1!(2250-1)!} 0.93^1 0.07^{2250-1} \\ & + \frac{2250!}{2!(2250-2)!} 0.93^2 0.07^{2250-2} + \dots \dots \\ & + \frac{2250!}{2125!(2250-2125)!} 0.93^{2125} 0.07^{2250-2125} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 40. Gráfica de la distribución binomial para n (2250).

Fuente: Minitab 2018.

Valor $p = 0.9995$

4.2.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.2.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 2125$ éxitos en la muestra

$n = 2250$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (13):

$$p < \left[1 + \frac{2250 - 2125}{(2125 + 1)F_{0.05, 2(2125+1), 2(2250-2125)}} \right]^{-1}$$

$$p < \left[1 + \frac{125}{2126 F_{0.05, 2(2126), 2(125)}} \right]^{-1}$$

$$p < \left[1 + \frac{125}{2126 F_{0.05, 4252, 250}} \right]^{-1}$$




Ilustración 41. Gráfica de la distribución de F (4252,250).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{125}{2126(1.171)} \right]^{-1}$$

$$p < (1.0502099)^{-1}$$

$$p < 0.95219$$

Con un nivel de confianza de 95% el prototipo emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para FCW y BSD con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites: inferior de 90% y superior de 95.219%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.3 Caso 2: contraste de hipótesis para probar la tasa general de éxito del prototipo LattePanda Delta 3 ante eventos de los sistemas FCW y BSD

General: Todas las pruebas realizadas para los sistemas de advertencia de colisión frontal y punto ciego con equipo LattePanda Delta 3.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 de los sistemas de advertencia de detección de colisión frontal y punto ciego es por lo menos de 93%.

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 de los sistemas de advertencia de detección de colisión frontal y punto ciego es menor de 93%.

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.10$, es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de β , se obtiene el valor de

$$\text{Potencia} = 1 - \beta \quad (4)$$

Sustituyendo el valor admitido de $\beta = 0.09951$ se obtiene el valor de potencia deseado:

$$\text{Potencia} = 1 - 0.09951 = 0.900490$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

4.3.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β

planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.3.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.09951$
- $Potencia = 1 - 0.09951 = 0.900490$
- $p_1 = 0.90$
- $n = ?$

4.3.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$Potencia = \Phi \left(\frac{p_0 - p_1 - z_{\alpha} \sqrt{\frac{p_0(1-p_0)}{n}}}{\sqrt{\frac{p_1(1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (10) de los valores planificados:

$$0.900490 = \Phi \left[\frac{(0.93 - 0.90) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.90(1-0.90)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.900490 = \Phi \left[\frac{(0.93 - 0.90) - 1.645 \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.90(1-0.90)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.900490.

Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 720 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, *Potencia* = 0.998859 y con acuerdo a la ecuación 8: $\beta = 1 - 0.900490 = 0.09951$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.90$, se decidió realizar este estudio con un tamaño de muestra de 720 pruebas para, a continuación, probar la hipótesis referenciada con el número 2 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos de los sistemas de advertencia de detección de colisión frontal y punto ciego es mayor o igual a 93%.

4.3.2 Prueba de hipótesis

4.3.2.1 Hipótesis estadística y nivel de significancia

$H_0: p \geq 0.93$

$H_1: p < 0.93$

$\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.3.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta vehículo/No detecta vehículo

Para $H_1: p < p_0$, el estadístico de prueba es:

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

x : N° de éxitos en la muestra

n : Tamaño de la muestra o número de pruebas a realizar

p_0 : Probabilidad de éxito (valor de p en la H_0)

q : Probabilidad de fracaso $q = 1 - p$

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.3.2.3 Cálculo del estadístico de prueba

Datos muestrales:

- $x = 676$ Número de éxitos en las pruebas realizadas.
- $n = 720$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 676 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p &= \frac{720!}{0!(720-0)!} 0.93^0 0.07^{720-0} + \frac{720!}{1!(720-1)!} 0.93^1 0.07^{720-1} \\ &+ \frac{720!}{2!(720-2)!} 0.93^2 0.07^{720-2} + \dots \\ &+ \frac{720!}{676!(720-676)!} 0.93^{676} 0.07^{720-676} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 42. Gráfica de la distribución binomial para n (720).

Fuente: Minitab 2018.

Valor $p = 0.8435$

4.3.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.3.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 676$ éxitos en la muestra

$n = 720$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (13):

$$p < \left[1 + \frac{720 - 676}{(676 + 1)F_{0.05, 2(676+1), 2(720-676)}} \right]^{-1}$$

$$p < \left[1 + \frac{44}{677 F_{0.05, 2(677), 2(44)}} \right]^{-1}$$

$$p < \left[1 + \frac{44}{677 F_{0.05, 1354, 88}} \right]^{-1}$$




Ilustración 43. Gráfica de la distribución de F (1354,88).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{44}{677(1.315)} \right]^{-1}$$

$$p < (1.049424)^{-1}$$

$$p < 0.952903$$

$$p < (1.056974)^{-1}$$

$$p < 0.952903$$

Con un nivel de confianza de 95% el prototipo emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para FCW y BSD con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites: inferior de 90% y superior de 95.29%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.4 Caso 3: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo Lenovo Ideapad ante eventos del sistema de BSD

Particular: Incluye las pruebas del prototipo con equipo Lenovo Ideapad para eventos del sistema de advertencia de punto ciego.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo ante eventos del sistema de advertencia de punto ciego es por lo menos de 93%

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo Lenovo ante eventos del sistema de advertencia de punto ciego es menor de 93%

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.05$, es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de $\beta = 0.00668$, se obtiene el valor de

$$\text{Potencia} = 1 - \beta \quad (4)$$

$$\text{Potencia} = 1 - 0.00668 = 0.993320$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

4.4.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.4.1.1 Hipótesis y valores estadísticos

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.00668$
- $Potencia = 1 - 0.00668 = 0.993320$
- $p_1 = 0.90$
- $n = ?$

4.4.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$Potencia = \Phi \left(\frac{p_0 - p_1 - z_{\alpha} \sqrt{\frac{p_0 (1-p_0)}{n}}}{\sqrt{\frac{p_1 (1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.993320 = \Phi \left[\frac{(0.93 - 0.90) - z_{0.05} \sqrt{\frac{0.93 (1-0.93)}{n}}}{\sqrt{\frac{0.90 (1-0.90)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.993320 = \Phi \left[\frac{(0.93 - 0.90) - 1.645 \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.90(1-0.90)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error substituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.993320.

Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 1500 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores substituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, *Potencia* = 0.993320 y con acuerdo a la ecuación 8: $\beta = 1 - 0.993320 = 0.00668$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.90$, se decidió realizar este estudio con un tamaño de muestra de 1,500 pruebas para, a continuación, probar la hipótesis referenciada con el número 3 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de punto ciego es por lo menos de 93%.

4.4.2 Prueba de hipótesis

4.4.2.1 Hipótesis estadística y nivel de significancia

- $H_0: p \geq 0.93$

- $H_1: p < 0.93$
- $\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.4.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta vehículo/No detecta vehículo

Para $H_1: p < p_0$, el estadístico de prueba es:

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

- x : N° de éxitos en la muestra
- n : Tamaño de la muestra o número de pruebas a realizar
- p_0 : Probabilidad de éxito (valor de p en la H_0)
- q : Probabilidad de fracaso

$$q = 1 - p \quad (7)$$

El Valor p se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.4.2.3 Cálculo del estadístico de prueba

Datos muestrales:

- $x = 1410$ Número de éxitos en las pruebas realizadas.

- $n = 1500$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 1410 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p &= \frac{1500!}{0!(1500-0)!} 0.93^0 0.07^{1500-0} + \frac{1500!}{1!(1500-1)!} 0.93^1 0.07^{1500-1} \\ &+ \frac{1500!}{2!(1500-2)!} 0.93^2 0.07^{1500-2} + \dots \\ &+ \frac{1500!}{1410!(1500-1410)!} 0.93^{1410} 0.07^{1500-1410} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 44. Gráfica de la distribución binomial para n (1500).

Fuente: Minitab 2018.

$$\text{Valor } p = 0.9443$$

4.4.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.4.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 1410$ éxitos en la muestra

$n = 1500$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (13):

$$p < \left[1 + \frac{1500 - 1410}{(1410 + 1)F_{0.05, 2(1410+1), 2(1500-1410)}} \right]^{-1}$$

$$p < \left[1 + \frac{90}{1411F_{0.05, 2(1411), 2(90)}} \right]^{-1}$$

$$p < \left[1 + \frac{90}{1411F_{0.05, 2822, 180}} \right]^{-1}$$




Ilustración 45. Gráfica de la distribución de F (2822,180).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{90}{1411(1.206)} \right]^{-1}$$

$$p < (1.052889)^{-1}$$

$$p < 0.949767$$

Con un nivel de confianza de 95% el prototipo con equipo Lenovo emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para BSD con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites: inferior de 90% y superior de 94.97%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.5 Caso 4: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo Lenovo Ideapad ante eventos del sistema de FCW

Particular: Incluye las pruebas del prototipo con equipo Lenovo Ideapad para eventos del sistema de advertencia de colisión frontal.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de colisión frontal es menor de 93%.

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.05$, es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de $\beta = 0.046923$ se obtiene el valor de

$$\text{Potencia} = 1 - \beta \quad (4)$$

$$\text{Potencia} = 1 - 0.046923 = 0.953077$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

4.5.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.5.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.046923$
- $\text{Potencia} = 1 - 0.046923 = 0.953077$
- $p_1 = 0.896$
- $n = ?$

4.5.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$\text{Potencia} = \Phi \left(\frac{p_0 - p_1 - z_\alpha \sqrt{\frac{p_0(1-p_0)}{n}}}{\sqrt{\frac{p_1(1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.953077 = \Phi \left[\frac{(0.93 - 0.896) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.896(1-0.896)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.953077 = \Phi \left[\frac{(0.93 - 0.896) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.896(1-0.896)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.953077. Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 750 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, *Potencia* = 0.953077 y con acuerdo a la ecuación 8: $\beta = 1 - 0.953077 =$

0.046923, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.896$, se decidió realizar este estudio con un tamaño de muestra de 750 pruebas para, a continuación, probar la hipótesis referenciada con el número 4 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo Lenovo Ideapad ante eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.

4.5.2 Prueba de hipótesis

4.5.2.1 Hipótesis estadística y nivel de significancia

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.5.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta vehículo/No detecta vehículo

Para $H_1: p < p_0$, el estadístico de prueba es:

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

x : N° de éxitos en la muestra

n : Tamaño de la muestra o número de pruebas a realizar

p_0 : Probabilidad de éxito (valor de p en la H_0)

q : Probabilidad de fracaso

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.5.2.3 Cálculo del estadístico de prueba

- $x = 715$ Número de éxitos en las pruebas realizadas.
- $n = 750$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 725 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p = & \frac{750!}{0!(750-0)!} 0.93^0 0.07^{750-0} + \frac{750!}{1!(750-1)!} 0.93^1 0.07^{750-1} \\ & + \frac{750!}{2!(750-2)!} 0.93^2 0.07^{750-2} + \dots \dots \\ & + \frac{750!}{715!(750-715)!} 0.93^{715} 0.07^{750-715} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 46. Gráfica de la distribución binomial para n (750).

Fuente: Minitab 2018.

Valor $p = 0.9967$

4.5.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.5.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 715$ éxitos en la muestra

$n = 750$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (9):

$$p < \left[1 + \frac{750 - 715}{(715 + 1)F_{0.05, 2(715+1), 2(750-715)}} \right]^{-1}$$

$$p < \left[1 + \frac{35}{716F_{0.05, 2(716), 2(35)}} \right]^{-1}$$

$$p < \left[1 + \frac{35}{716F_{0.05, 1432, 70}} \right]^{-1}$$




Ilustración 47. Gráfica de la distribución de F (1432,70).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{35}{716(1.361)} \right]^{-1}$$

$$p < (1.0359167)^{-1}$$

$$p < 0.965328$$

Con un nivel de confianza de 95% el prototipo con equipo Lenovo emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para FCW con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites: inferior de 90% y superior de 96.5328%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.6 Caso 5: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de BSD

Particular: Incluye las pruebas del prototipo con equipo LattePanda Delta 3 para eventos del sistema de advertencia de punto ciego.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de punto ciego es por lo menos de 93%.

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de punto ciego es menor de 93%.

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.10$ es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de $\beta = 0.090269$ se obtiene el valor de

$$\text{Potencia} = 1 - \beta \quad (4)$$

$$\text{Potencia} = 1 - 0.090269 = 0.909731$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

4.6.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.6.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$
- $\alpha = 0.05$
- $\beta = 0.090269$
- $Potencia = 1 - 0.090269 = 0.909731$
- $p_1 = 0.893$
- $n = ?$

4.6.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$Potencia = \Phi \left(\frac{p_0 - p_1 - z_{\alpha} \sqrt{\frac{p_0(1-p_0)}{n}}}{\sqrt{\frac{p_1(1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.909731 = \Phi \left[\frac{(0.93 - 0.893) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.893(1-0.893)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.909731 = \Phi \left[\frac{(0.93 - 0.893) - 1.645 \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.893(1-0.893)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.909731. Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 480 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, *Potencia* = 0.909731 y con acuerdo a la ecuación 4: $\beta = 1 - 0.909731 = 0.090269$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.893$ se decidió realizar este estudio con un tamaño de muestra de 480 pruebas para, a continuación, probar la hipótesis referenciada con el número 5 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de punto ciego es por lo menos de 93%.

4.6.2 Prueba de hipótesis

4.6.2.1 Hipótesis estadística y nivel de significancia

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$

- $\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.6.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta posible evento de colisión/No detecta

Para $H_1: p < p_0$, el estadístico de prueba es:

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

x : N° de éxitos en la muestra

n : Tamaño de la muestra o número de pruebas a realizar

p_0 : Probabilidad de éxito (valor de p en la H_0)

q : Probabilidad de fracaso

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.6.2.3 Cálculo del estadístico de prueba

Datos muestrales:

- $x = 446$ Número de éxitos en las pruebas realizadas.
- $n = 480$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0

- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 446 | p = 0.93]$$

Sustituyendo

$$\begin{aligned} \text{Valor } p &= \frac{480!}{0!(480-0)!} 0.93^0 0.07^{480-0} + \frac{480!}{1!(480-1)!} 0.93^1 0.07^{480-1} \\ &+ \frac{480!}{2!(480-2)!} 0.93^2 0.07^{480-2} + \dots \\ &+ \frac{480!}{446!(480-446)!} 0.93^{446} 0.07^{480-446} \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 48. Gráfica de la distribución binomial para n (480).

Fuente: Minitab 2018.

$$\text{Valor } p = 0.4969$$

4.6.2.4 Decisión

Se tiene que $\text{Valor } p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.6.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n - x}{(x + 1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 446$ éxitos en la muestra

$n = 480$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (9):

$$p < \left[1 + \frac{480 - 446}{(446 + 1)F_{0.05, 2(446+1), 2(480-446)}} \right]^{-1}$$

$$p < \left[1 + \frac{34}{447F_{0.05, 2(447), 2(34)}} \right]^{-1}$$

$$p < \left[1 + \frac{34}{447F_{0.05, 894, 68}} \right]^{-1}$$




Ilustración 49. Gráfica de la distribución de $F(894, 68)$.

Fuente: Minitab 2018.

$$p < \left[1 + \frac{34}{447(1.371)} \right]^{-1}$$

$$p < (1.055479)^{-1}$$

$$p < 0.947437$$

Con un nivel de confianza de 95% el prototipo con equipo LattePanda Delta 3 emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para BSD con una proporción real o poblacional de éxito (detección correcta) dentro del intervalo con límites: inferior de 90% y superior de 94.7437%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

4.7 Caso 6: contraste de hipótesis para probar la tasa particular de éxito del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de FCW

Particular: Incluye las pruebas del prototipo con equipo LattePanda Delta 3 para eventos del sistema de advertencia de colisión frontal.

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 para eventos del sistema de advertencia de colisión frontal es por lo menos de 93%.

$H_1: p < 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 para eventos del sistema de advertencia de colisión frontal es menor de 93%.

$\alpha = 0.05$ Nivel de significancia: Es la probabilidad de cometer el error tipo I: rechazar H_0 cuando H_0 es verdadera.

$\beta \leq 0.10$ es la probabilidad de cometer el error tipo II: no rechazar H_0 cuando H_0 es falsa.

Potencia: Es la probabilidad de rechazar H_0 cuando H_0 es falsa.

Sustituyendo el valor admitido de $\beta = 0.099935$ se obtiene el valor de

$$\text{Potencia} = 1 - \beta \tag{4}$$

$$\text{Potencia} = 1 - 0.099935 = 0.900065$$

El interés se centra en conocer si la tasa o proporción poblacional de éxitos es, al nivel de significancia de 0.05, igual o mayor de 0.93 y en una sección posterior, mediante la

estimación del intervalo de confianza de 95%, determinar el rango de valores entre los cuales se ubica el verdadero valor de la tasa de éxitos (p) del prototipo en cuestión.

Cabe recordar cuando se utiliza el método de Prueba de hipótesis, se pueden cometer dos tipos de error, Error tipo I y Error tipo II, la cuestión es que la probabilidad de cometerlos sea razonablemente baja. El control de ambos tipos de error se lleva a cabo al determinar la potencia de la muestra empleada. Si bien el valor aceptado de α (la probabilidad de cometer el error tipo I) es determinado por el investigador, también es cierto que el valor de α se relaciona en razón indirecta con el tamaño de muestra (n). Por lo tanto, es importante llevar a cabo una buena selección de los valores planificados de α y β , de lo contrario, quizá se obtendrían tamaños de muestras innecesariamente elevados con relación a la potencia proyectada o muy pequeños con una potencia exigua.

4.7.1 Cálculo de la potencia de la muestra empleada en el estudio

En esta sección se procede a determinar el número de pruebas (n) para cada atributo de interés necesarias para que la Prueba de hipótesis se realice considerando los valores de α y β planificados, cabe recordarlos, $\alpha = 0.05$ y el valor de β elegido. Además, habrá que establecer el valor de la proporción de comparación p_1 .

Proporción de comparación: La diferencia entre la proporción de comparación (p_1) y la proporción hipotetizada (p_0) es la mínima diferencia que una prueba para una proporción puede detectar (Minitab, LLC., 2023).

Por ejemplo, si se considera relevante que el muestreo detecte diferencias a partir de -3% respecto al valor de p en H_0 , en este caso $H_0 = 0.93$, p_1 será igual a 0.90 debido a que $0.93 - 0.03 = 0.90$.

4.7.1.1 Hipótesis y valores planificados

- $H_0: p \geq 0.93$
- $H_1: p < 0.93$

- $\alpha = 0.05$
- $\beta = 0.099935$
- $Potencia = 1 - 0.099935 = 0.900065$
- $p_1 = 0.876$
- $n = ?$

4.7.1.2 Cálculo de la potencia de la muestra

Potencia unilateral ($H_1: p < p_0$):

$$Potencia = \Phi \left(\frac{p_0 - p_1 - z_\alpha \sqrt{\frac{p_0(1-p_0)}{n}}}{\sqrt{\frac{p_1(1-p_1)}{n}}} \right) \quad (5)$$

Φ : Función de distribución acumulativa de la distribución normal estándar.

Realizando la sustitución en la ecuación (5) de los valores planificados:

$$0.900065 = \Phi \left[\frac{(0.93 - 0.876) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.876(1-0.876)}{n}}} \right]$$

Mediante Minitab se obtiene el valor de $-z_{0.05}$, como puede observarse en la ilustración 37:

$$0.900065 = \Phi \left[\frac{(0.93 - 0.876) - z_{0.05} \sqrt{\frac{0.93(1-0.93)}{n}}}{\sqrt{\frac{0.876(1-0.876)}{n}}} \right]$$

Como podrá observarse, en este punto se tiene una ecuación con n como única incógnita por lo que sigue realizar un proceso de ensayo y error sustituyendo diferentes valores de n hasta lograr que el valor de potencia sea precisamente 0.900065. Mediante Minitab se realizó el proceso de prueba y error utilizando la opción “*Power and sample size*” dentro del menú *Estadísticas*, necesario para encontrar el valor de n que equilibra la ecuación. Dicho valor es

$$n = 240 \text{ Pruebas}$$

Se podrá notar que esta ecuación y los valores sustituidos en ella, aseguran el cumplimiento de las condiciones especificadas en los valores planificados y que condujo la labor de campo necesaria para recabar el número de valores de prueba requeridos por el diseño del experimento estadístico.

Considerando los valores planeados en el diseño del experimento estadístico, esto es, $\alpha = 0.05$, $Potencia = 0.900065$ con acuerdo a la ecuación 8: $\beta = 1 - 0.900065 = 0.099935$, así mismo $H_0 = 0.93$ y una proporción de comparación $p_1 = 0.876$ se decidió realizar este estudio con un tamaño de muestra de 240 pruebas para, a continuación, probar la hipótesis referenciada con el número 6 en los objetivos específicos de investigación planteada en la sección 1.1.3.5, a saber:

$H_0: p \geq 0.93$ La proporción de éxitos del prototipo con equipo LattePanda Delta 3 ante eventos del sistema de advertencia de colisión frontal es menor de 93%.

4.7.2 Prueba de hipótesis

4.7.2.1 Hipótesis estadística y nivel de significancia

$H_0: p \geq 0.93$

$H_1: p < 0.93$

$\alpha = 0.05$ (Probabilidad de incurrir en el Error Tipo I: probabilidad de rechazar H_0 cuando H_0 es verdadera)

4.7.2.2 Estadístico de prueba

Supuesto:

Población bajo estudio es binomial: Detecta evento de posible colisión/No detecta

Para $H_1: p < p_0$, el estadístico de prueba es:

$$\text{Valor } p = P[X \leq x | p = p_0], \quad (6)$$

donde X es la variable binomial con resultados posibles: éxito o fracaso, entonces X es una variable aleatoria discreta.

Sea

x : N° de éxitos en la muestra

n : Tamaño de la muestra o número de pruebas a realizar

p_0 : Probabilidad de éxito (valor de p en la H_0)

q : Probabilidad de fracaso

$$q = 1 - p \quad (7)$$

El *Valor p* se calcula desde la Función de probabilidad binomial:

$$P[X = x] = \frac{n!}{x!(n-x)!} p^x q^{n-x} \quad (8)$$

X : Número de éxitos en la muestra

x : Número de éxitos de interés en la muestra

4.7.2.3 Cálculo del estadístico de prueba

Datos muestrales:

- $x = 230$ Número de éxitos en las pruebas realizadas.
- $n = 240$ Número total de pruebas realizadas
- $p_0 = 0.93$ Valor de p en la H_0
- q : Probabilidad de fracaso
- $q = 1 - 0.93 = 0.07$

Realizando la sustitución de los valores en (6):

$$\text{Valor } p = P[X \leq 230 | p = 0.93]$$

Sustituyendo

$$\begin{aligned}
 \text{Valor } p &= \frac{240!}{0!(240-0)!} 0.93^0 0.07^{240-0} + \frac{240!}{1!(240-1)!} 0.93^1 0.07^{240-1} \\
 &+ \frac{240!}{2!(240-2)!} 0.93^2 0.07^{240-2} + \dots \dots \\
 &+ \frac{240!}{230!(240-230)!} 0.93^{230} 0.07^{240-230}
 \end{aligned}$$

Este valor de probabilidad se calculó mediante Minitab:




Ilustración 50. Gráfica de la distribución binomial para n (240).

Fuente: Minitab 2018.

$$\text{Valor } p = 0.975$$

4.7.2.4 Decisión

Se tiene que Valor $p > \alpha$.

Por lo tanto, al nivel de significancia α de 0.05 no se rechaza H_0 . La información proporcionada por la muestra de pruebas no es significativa, es decir, no es suficiente para rechazar H_0 .

4.7.2.5 Intervalo de confianza unilateral de 95% para p

Método del intervalo de confianza exacto de Clopper-Pearson:

$$p < \left[1 + \frac{n-x}{(x+1)F_{\alpha, 2(x+1), 2(n-x)}} \right]^{-1} \quad (9)$$

Datos muestrales:

$x = 230$ éxitos en la muestra

$n = 240$ Pruebas (Tamaño de la muestra)

Realizando la sustitución de los valores en (9):

$$p < \left[1 + \frac{240 - 230}{(230 + 1)F_{0.05, 2(230+1), 2(240-230)}} \right]^{-1}$$

$$p < \left[1 + \frac{10}{231F_{0.05, 2(231), 2(10)}} \right]^{-1}$$

$$p < \left[1 + \frac{10}{231F_{0.05, 462, 20}} \right]^{-1}$$




Ilustración 51. Gráfica de la distribución de F (462,20).

Fuente: Minitab 2018.

$$p < \left[1 + \frac{10}{231(1.857)} \right]^{-1}$$

$$p < (1.0233118)^{-1}$$

$$p < 0.977219$$

Con un nivel de confianza de 95% el prototipo con equipo LattePanda Delta 3 emite alertas audiovisuales al conductor y pasajeros de un vehículo automotor ante posibles riesgos viales para FCW con una proporción real o poblacional de éxito (detección correcta) dentro del

intervalo con límites: inferior de 90% y superior de 97.7219%, de tal forma que el valor planificado especificado en los objetivos del caso de estudio (93% o mayor), se encuentra dentro de los límites del intervalo.

V. ANÁLISIS DE RESULTADOS

5.1 Análisis de los resultados obtenidos mediante Prototipo global (Lenovo Ideapad y LattePanda Delta 3)

En las siguientes tablas, se ilustran los tipos de escenarios BSD y FCW con los resultados obtenidos en cada una de sus zonas de riesgo mediante el prototipo global. En la sección anterior, se definió que la tasa de éxito del prototipo deberá encontrarse en el intervalo de 90% y 94.99% como un sistema global.

Resultados obtenidos de las pruebas realizadas en campo como prototipo global y ADAS (FCW Y BSD).

Tabla 13. Resultados obtenidos pruebas BSD realizadas en campo para prototipo 1.

PROTOTIPO						
GLOBAL						
Lenovo Ideapad Gaming & LattePanda Delta 3						
BSD	N° Aciertos		N° Fallos		% Asertividad	
Zona de riesgo	LP ³	LC ⁴	LP	LC	LP	LC
Alto	350	361	20	9	95	98
Medio	338	357	32	13	91	96
Bajo	231	219	19	31	92	88
N° Total de pruebas	370*		Media Asertividad		93.33 %	

³ Lado Piloto: pruebas realizadas desde la posición del lado lateral izquierdo.

⁴ Lado Copiloto: pruebas realizadas desde la posición del lado lateral derecho.

* Número de pruebas realizadas por zona de riesgo, con excepción de la zona de riesgo bajo donde se realizaron 250 pruebas.

Tabla 14. Resultados obtenidos pruebas FCW realizadas en campo para prototipo 1.

PROTOTIPO			
GLOBAL			
Lenovo Ideapad Gaming & LattePanda Delta 3			
FCW	N° Aciertos	N° Fallos	% Asertividad
Zona de riesgo	FRONTAL	FRONTAL	FRONTAL
Alto	359	11	97
Medio	355	15	96
Bajo	231	19	92
N° Total de pruebas	250	Media Asertividad	95.12 %

El análisis estadístico indica que el prototipo global tiene una tasa de éxito en la detección de posibles eventos de riesgo de 94.22%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 94.99%. Dado que el valor de 93% se encuentra dentro de este intervalo y el valor p es 0.9981 (muy superior al umbral de significancia de 0.05), en conclusión no hay suficiente evidencia para rechazar la hipótesis global nula. Por lo tanto, se sostiene que el prototipo cumple con el estándar requerido, manteniendo una proporción de éxitos igual o superior al 93% con un alto grado de confianza.

5.2 Análisis de los resultados obtenidos mediante Lenovo Ideapad

En las siguientes tablas, se ilustran los resultados obtenidos en las pruebas de campo para cada uno de los objetivos específicos del presente caso de estudio. En el capítulo 4, se definió que las tasas de éxito del prototipo, ya sea de forma global, general y/o particular deberán encontrarse en el intervalo de 90% y 96%. En las tablas 15 al 17, se observa el número de fallos por zona obtenidos en las pruebas de campo, reflejando la zona de riesgo bajo con una

menor tasa de éxito. Sin embargo, esta zona no representa ningún riesgo para el conductor y/o pasajero del vehículo.

Tabla 15. Resultados obtenidos pruebas realizadas en campo para BSD (lado piloto).

Escenario BSD (lado piloto)	Tasa de éxito detección deseada.	Número de fallos-estimados en la activación del ADAS	Tasa de éxito detección obtenida.	Número de fallos-obtenidos en la activación del ADAS
zona crítica	93%	18 fallos	94%	14 fallos
zona precautoria	93%	18 fallos	95%	12 fallos
zona riesgo bajo	93%	18 fallos	92%	19 fallos

Tabla 16. Resultados obtenidos pruebas realizadas en campo para BSD (lado copiloto).

Escenario BSD lado copiloto	Tasa de éxito detección deseada.	Número de fallos-estimados en la activación del ADAS	Tasa de éxito detección obtenida	Número de Falsos positivos-obtenidos en la activación del ADAS
zona crítica	93%	18 fallos	97%	7 fallos
zona precautoria	93%	18 fallos	97%	7 fallos
zona riesgo bajo	93%	18 fallos	88%	31 fallos

Tabla 17. Resultados obtenidos pruebas realizadas en campo para FCW (frontal).

Escenario FCW frontal	Tasa de éxito detección deseada.	Número de fallos-estimados en la activación del ADAS	Tasa de éxito detección obtenida	Número de Falsos positivos- obtenidos en la activación del ADAS
zona crítica	93%	18 fallos	96%	9 fallos
zona precautoria	93%	18 fallos	97%	7 fallos
zona riesgo bajo	93%	18 fallos	92%	19 fallos

5.2.1 Interpretación de resultados

Como se indicó previamente, el primer objetivo específico consiste en estimar la tasa general de éxito del prototipo del sistema de advertencia para la detección de posibles eventos de punto ciego y colisión frontal, utilizando el equipo Lenovo Ideapad, en tres niveles de riesgo: bajo, medio y alto, con una meta mínima del 93%.

El análisis estadístico revela que el prototipo tiene una tasa general de éxito en la detección de posibles eventos de riesgos de colisión y punto ciego de 94.44%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 95.22%. Dado que el 93% está dentro de este intervalo y el valor p es 0.9975 (muy superior al umbral de significancia de 0.05), no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número uno. Por lo tanto, se concluye que el prototipo cumple con el estándar requerido, manteniendo una tasa de éxito igual o superior al 93% con un alto grado de confianza.

De manera similar, el tercer objetivo específico se centraba en estimar la tasa de éxito particular del sistema de advertencia de colisión frontal en los tres niveles mencionados, utilizando el equipo Lenovo Ideapad, con un objetivo de al menos el 93%.

El análisis estadístico indica que el prototipo para la detección de colisiones frontales logra una tasa particular de éxito del 95.33%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 96.53%. Dado que el 93% se encuentra dentro de este intervalo y el valor p es 0.9967 (mayor que el umbral de significancia de 0.05), se concluye que no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número tres. Por lo tanto, se sostiene que el prototipo cumple con el estándar requerido, con una tasa de éxito igual o superior al 93% y un alto grado de confianza.

Por último, el cuarto objetivo específico se enfocaba en estimar la tasa de éxito particular del sistema de advertencia para la detección de punto ciego, también en tres niveles, utilizando un equipo Lenovo Ideapad, con un objetivo mínimo del 93%.

El análisis estadístico sugiere que el prototipo para la detección de puntos ciegos presenta una tasa particular de éxito de 94%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 94.98%. Dado que el 93% se encuentra dentro de este intervalo y el valor p es 0.9443 (mayor que el umbral de significancia de 0.05), se concluye que no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número cuatro. Por lo tanto, se confirma que el prototipo cumple con el estándar requerido, manteniendo una tasa de éxito igual o superior al 93% con un alto grado de confianza.

5.3 Análisis de los resultados obtenidos mediante LattePanda Delta 3

En las siguientes tablas, se ilustran los resultados obtenidos en las pruebas de campo para cada uno de los objetivos específicos del presente caso de estudio mediante LattePanda Delta 3. En el capítulo 3, se definió que las tasas de éxito del prototipo, ya sea de forma global, general y/o particular deberán encontrarse en el intervalo de 90% y 96%. En las tablas 18 al 20, se observa el número de fallos por zona obtenidos en las pruebas de campo, reflejando la zona de riesgo bajo con una menor tasa de éxito. Sin embargo, esta zona no representa ningún riesgo para el conductor y/o pasajero del vehículo.

Tabla 18. Resultados obtenidos pruebas realizadas en campo para BSD (lado piloto).

Escenario BSD (lado piloto)	Tasa de éxito detección deseada.	Número de fallos-estimados en la activación del ADAS	Tasa de éxito detección obtenida.	Número de fallos-obtenidos en la activación del ADAS
zona crítica	93%	9 fallos	95%	6 fallos
zona precautoria	93%	9 fallos	83%	20 fallos

Tabla 19. Resultados obtenidos pruebas realizadas en campo para BSD (lado copiloto).

Escenario BSD lado copiloto	Tasa de éxito detección deseada.	Número de fallos- estimados en la activación del ADAS	Tasa de éxito detección obtenida	Número de Falsos positivos- obtenidos en la activación del ADAS
zona crítica	93%	9 fallos	98%	2 fallos
zona precautoria	93%	9 fallos	95%	6 fallos

Tabla 20. Resultados obtenidos pruebas realizadas en campo para FCW (frontal).

Escenario FCW frontal	Tasa de éxito detección deseada.	Número de fallos- estimados en la activación del ADAS	Tasa de éxito detección obtenida	Número de Falsos positivos- obtenidos en la activación del ADAS
zona crítica	93%	9 fallos	98%	2 fallos
zona precautoria	93%	9 fallos	93%	8 fallos

5.3.1 Interpretación de resultados

Como se mencionó previamente, el segundo objetivo específico era estimar la tasa general de éxito del prototipo del sistema de advertencia para la detección de posibles eventos de punto ciego y colisión frontal utilizando el equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto. La meta era alcanzar una tasa mínima del 93%.

El análisis estadístico muestra que el prototipo, al usarse con el equipo LattePanda para eventos de colisión lateral y frontal, presenta una tasa de éxito del 93.89%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 95.29%. Dado que el valor del 93% está dentro de este intervalo y el valor p obtenido es 0.8435 (superior al umbral de significancia de 0.05), no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número dos. Por lo tanto, se concluye que el prototipo cumple con el estándar requerido, manteniendo una proporción de éxitos igual o superior al 93% con un alto grado de confianza.

De manera similar, el quinto objetivo específico se enfocaba en estimar la tasa de éxito particular del sistema de advertencia de colisión frontal con el equipo LattePanda Delta 3 en los tres niveles mencionados, con una meta mínima del 93%.

El análisis estadístico de las pruebas realizadas con el equipo LattePanda para eventos de colisión frontal muestra una tasa de éxito del 95.83%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 97.72%. Dado que el valor planificado del 93% se encuentra dentro de este intervalo y el valor p obtenido es 0.975 (mayor que el nivel de significancia de 0.05), no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número cinco. Así, se concluye que el prototipo cumple con el estándar requerido, manteniendo una proporción de éxitos igual o superior al 93% con alta confianza.

Por último, el sexto objetivo específico se centraba en estimar la tasa de éxito del prototipo para la detección de puntos ciegos con el equipo LattePanda Delta 3 en tres niveles: bajo, medio y alto, con un objetivo mínimo del 93%.

El análisis estadístico de las pruebas realizadas con el equipo LattePanda para eventos de colisión frontal muestra una tasa de éxito del 93.18%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 97.7219%. Dado que el valor planificado del 93% se encuentra dentro de este intervalo y el valor p obtenido es 0.975 (mayor que el nivel de significancia de 0.05), no hay suficiente evidencia para rechazar la hipótesis nula referenciada en los objetivos específicos con el número seis. Así, se concluye que el prototipo cumple con el estándar requerido, manteniendo una proporción de éxitos igual o superior al 93% con alta confianza.

5.4 Comparación del posprocesamiento del sistema entre Lenovo Ideapad y LattePanda Delta 3

Al comparar los dispositivos Lenovo Ideapad y LattePanda Delta 3, es crucial considerar no solo el porcentaje de uso de la CPU, sino también el rendimiento general y la eficiencia del sistema en completar las tareas de captura y procesamiento de video en tiempo real utilizando las tres cámaras simultáneamente. Además, otros factores como el uso de memoria RAM, el tiempo de detección, y el rendimiento térmico deben ser tomados en cuenta para una evaluación completa.

5.4.1 Tiempos de detección

Para el siguiente análisis se ejecutó el código en ambos dispositivos de manera alterna, esto debido a que únicamente se contaba con los 3 dispositivos de captura de video mencionados en el capítulo 2. Durante las pruebas se monitoreo y registro la utilización de CPU mientras el sistema se estaba ejecutando. Fue importante tomar mediciones en intervalos y condiciones similares para obtener una imagen clara del uso de CPU durante la ejecución.

La comparación de las mediciones de utilización de CPU entre ambos dispositivos, se pueden observar a través del siguiente gráfico logrando visualizar las diferencias en el tiempo de detección en ambos dispositivos.




Ilustración 52. Comparación de tiempo de detección entre dispositivos .

Fuente: Elaboración propia.

Una vez recopilado la información de una muestra de las pruebas realizadas en campo se procedió a su análisis, el cual contempla los siguientes datos:

- Número de muestras analizadas: 87
- Tiempos de Detección (en segundos): Tiempo 1 y Tiempo 2
- Tiempo 1: Prototipo Lenovo Ideapad Gaming
- Tiempo 2: Prototipo LattePanda Delta 3

A partir del análisis de los tiempos de detección registrados en 87 muestras para dos dispositivos distintos, se obtuvieron resultados significativos en cuanto a rendimiento y consistencia. El promedio de los tiempos de detección fue de 0.3640 segundos para el Prototipo 1 y 0.6331 segundos para el Prototipo 2, mostrando que el Prototipo 1 es más rápido en promedio.

Este análisis se llevó a cabo mediante la siguiente metodología.

1. Promedio de Tiempos de Detección:

Se calculó el promedio de los tiempos de detección para ambos dispositivos.

2. Diferencia Promedio entre Tiempos:

Se evaluó la diferencia promedio entre los tiempos de detección de ambos dispositivos.

3. Varianza y Desviación Estándar:

Se calculó la varianza y la desviación estándar para ambos conjuntos de datos para entender la dispersión de los tiempos de detección.

4. Comparación Individual:

Se compararán los tiempos de detección de cada muestra entre los dos dispositivos para identificar si uno es consistentemente más rápido que el otro.

Análisis de Tiempos de Detección

1. Promedio de Tiempos de Detección:

Prototipo 1:

$x_1 = 0.407669067, x_2 = 0.277806044, x_3 = 0.353164673, x_4 = 0.264431238, x_5 = 0.345883608, \dots, x_{87} = 0.435470342$

Prototipo 2:

$x_1 = 0.395210742, x_2 = 0.667201757, x_3 = 0.954193592, x_4 = 0.400528192, x_5 = 0.630522489, \dots, x_{87} = 0.639506340$

Media

Ecuación 10. Expresión de la Media de una muestra.

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad (10)$$

$$\mu = \frac{x_1 + x_2 + x_3 + x_4 + x_5 + \dots + x_{87}}{87}$$

Prototipo 1:

$$\mu_1 = \frac{x_1 + x_2 + x_3 + x_4 + x_5 + \dots + x_{87}}{87} = 0.363975366$$

Prototipo 2:

$$\mu_2 = \frac{x_1 + x_2 + x_3 + x_4 + x_5 + \dots + x_{87}}{87} = 0.633124058$$

2. Diferencia Promedio entre Tiempos

La Diferencia Promedio entre los Tiempos de Detección fue de 0.2691 segundos, sugiriendo que el Prototipo 2 tarda alrededor de 0.27 segundos más en realizar las detecciones en comparación con el Prototipo 1.

$$\text{Tiempo 2} - \text{Tiempo 1} = 0.2691 \text{ segundos}$$

3. Desviación Estándar y Varianza

Desviación Estándar

Ecuación 11. Expresión de la Desviación Estándar de una muestra.

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (11)$$

Diferencia de cuadrados

Ecuación 12. Expresión de la Diferencia de Cuadrados de una muestra.

$$(x_{1...87} - \mu)^2 \quad (12)$$

Prototipo 1:

$$\begin{aligned} (x_1 - \mu)^2 &= (0.407669067 - 0.363975366)^2 = 0.00190914 \\ (x_2 - \mu)^2 &= (0.277806044 - 0.363975366)^2 = 0.007425152 \\ (x_3 - \mu)^2 &= (0.353164673 - 0.363975366)^2 = 0.000116871 \\ (x_4 - \mu)^2 &= (0.264431238 - 0.363975366)^2 = 0.009909033 \\ (x_5 - \mu)^2 &= (0.345883608 - 0.363975366)^2 = 0.000327312 \\ &\dots \\ (x_{87} - \mu)^2 &= (0.435470342 - 0.363975366)^2 = 0.005111532 \end{aligned}$$

Prototipo 2:

$$\begin{aligned} (x_1 - \mu)^2 &= (0.395210742 - 0.633124058)^2 = 0.056602745 \\ (x_2 - \mu)^2 &= (0.667201757 - 0.633124058)^2 = 0.001161289 \\ (x_3 - \mu)^2 &= (0.954193592 - 0.633124058)^2 = 0.103085645 \\ (x_4 - \mu)^2 &= (0.400528192 - 0.633124058)^2 = 0.054100836 \\ (x_5 - \mu)^2 &= (0.630522489 - 0.633124058)^2 = 0.000006768 \\ &\dots \\ (x_{87} - \mu)^2 &= (0.435470342 - 0.633124058)^2 = 0.000040733 \end{aligned}$$

Suma de Diferencias al Cuadrado

Ecuación 13. Expresión Suma de Cuadrados de una muestra.

$$\sum_{i=1}^{87} (x_i - \mu)^2 \quad (13)$$

Prototipo 1:

$$\begin{aligned} \sum_{i=1}^{87} (x_i - \mu)^2 &= 0.00190914 + 0.007425152 + 0.000116871 + 0.009909033 \\ &\quad + 0.000327312 + \dots + 0.005111532 = 0.4486999999999998 \end{aligned}$$

Prototipo 2:

$$\begin{aligned} \sum_{i=1}^{87} (x_i - \mu)^2 &= 0.056602745 + 0.001161289 + 0.103085645 + 0.054100836 \\ &\quad + 0.000006768 + \dots + 0.000040733 = 3.1090000000000013 \end{aligned}$$

Desviación Estándar

[ver ecuación 11]

Prototipo 1:

$$s = \sqrt{\frac{1}{87-1}(0.4487)} = 0.0722$$

Prototipo 2:

$$s = \sqrt{\frac{1}{87-1}(3.109)} = 0.1901$$

Varianza

Ecuación 14. Expresión de la Varianza de una muestra.

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (14)$$

[ver ecuación 14]

Prototipo 1:

$$s^2 = \frac{1}{87-1}(0.4487) = 0.0052$$

Prototipo 2:

$$s^2 = \frac{1}{87-1}(3.109) = 0.0362$$

5.4.2 Comparación Individual

En cuanto a la Varianza y Desviación Estándar, se observó una varianza de 0.0052 y una desviación estándar de 0.0722 en los tiempos de detección del Prototipo 1, mientras que el Prototipo 2 presentó una varianza de 0.0361 y una desviación estándar de 0.1901. Esto indica que los tiempos de detección del Prototipo 1 son no solo más rápidos, sino también más consistentes y predecibles en comparación con los del Prototipo 2, que muestran una mayor dispersión y variabilidad. En conclusión, el Prototipo 1 no solo es más rápido en promedio, sino que también demuestra un rendimiento más estable y eficiente. Por otro lado, el Prototipo

2, aunque más lento, enfrenta factores que incrementan la variabilidad de sus tiempos de detección, como diferente optimización del software y diferencias en el hardware.

5.4.3 Memoria RAM

El tiempo de detección de los dispositivos puede afectar la memoria RAM de varias maneras, dependiendo de cuantas detecciones se realizan en un mismo intervalo de tiempo y la gestión de los recursos de software y hardware en cada dispositivo. Por ejemplo, una mayor sensibilidad en la detección de objetos, especialmente si el procesamiento es más intensivo en recursos o clases generando que las estructuras de datos utilizados requieran más memoria. La gestión eficiente de la memoria y la optimización del código fueron clave para minimizar el impacto y rendimiento del sistema en el dispositivo LattePanda Delta 3 debido a sus características de portabilidad.

El rendimiento de los dispositivos empleados en tareas de detección es crucial en diversos ámbitos, desde la captura hasta el procesamiento de los datos. A continuación, se comparan los usos de memoria RAM en los dispositivos, referidos como Prototipo 1 y Prototipo 2. La evaluación se basa en un conjunto de datos que reflejan el uso promedio de memoria RAM durante las operaciones.

Tabla 23. Rendimiento de la memoria RAM en Lenovo Ideapad Gaming 3 durante detecciones.

Lenovo Ideapad	Uso de memoria RAM %
Iteración	
1	53 %
2	51 %
3	49 %
4	52 %
5	54 %

Tabla 24. Rendimiento de la memoria RAM en LattePanda Delta 3 durante detecciones.

LattePanda Delta 3	Uso de memoria RAM %
Iteración	
1	61 %
2	63 %
3	62 %

4	65 %
5	63 %

Considerando que el Prototipo 1 tuvo un uso promedio de RAM del 51% y el Prototipo 2 del 62%, esto sugiere que el Prototipo 1 maneja los recursos de memoria de manera más eficiente que el Dispositivo 2. El mayor uso de RAM en el Prototipo 2 podría estar contribuyendo a sus tiempos de detección más prolongados, afectando negativamente su rendimiento general. Para mejorar el rendimiento del Prototipo 2, sería necesario optimizar la gestión de memoria o incrementar su capacidad de memoria de 4 a 8 Gb. Esto proporciona una base para futuras mejoras en el rendimiento del Prototipo 2, destacando la importancia de una gestión eficiente de los recursos de memoria y CPU.

5.4.4 Rendimiento térmico y CPU

El Prototipo 1 opera a una temperatura promedio de 73 grados Celsius, mientras que el Prototipo 2 opera a una temperatura promedio de 83 grados Celsius ambos al momento de ejecutar el sistema e inicializar las detecciones. La mayor temperatura del Prototipo 2 indica un mayor estrés térmico debido a un mayor uso de recursos (CPU y RAM) como podemos observar en la ilustración 53, donde el CPU opera a un promedio de 97%.

Las temperaturas operativas más altas pueden llevar a una reducción de la vida útil del hardware y a una mayor probabilidad de estrangulamiento térmico, donde el rendimiento se redujo para evitar el sobrecalentamiento.

Tabla 25. Resultados obtenidos durante la realización de las pruebas en ambos prototipos.

Lenovo Ideapad Gaming con procesador AMD Ryzen 7 4800H con Gráficos Radeon integrados.




Ilustración 53. Comparación de tiempo de detección entre prototipos.
Fuente: Elaboración propia.

LattePanda Delta 3 con Intel(R) Celeron(R) N5105.




Ilustración 54. Comparación de tiempo de detección entre prototipos.
Fuente: Elaboración propia.

En las ilustraciones 53 y 54 se observa que la variabilidad en los tiempos de detección entre los dos dispositivos se debe principalmente a diferencias en hardware. El Lenovo Ideapad, con un procesador de más núcleos, utiliza solo el 64% de su capacidad, lo que le permite procesar de manera más eficiente. En cambio, el LattePanda Delta 3 utiliza en promedio el 97% de su capacidad, lo que incrementa sus tiempos de detección.

VI. CONCLUSIONES

Las conclusiones de esta investigación no se exponen como algo que ocurra en todo ambiente vial, ya que no se pretende generalizar, sino que, a partir de un estudio de caso, se trata de evidenciar algunas de las situaciones de detección posibles. El software se probó en diferentes áreas, donde cada conjunto de pruebas tenía diferentes condiciones ambientales (apegadas a los requisitos de realización de pruebas) y de iluminación. El análisis estadístico realizado sobre el prototipo global del sistema de advertencia para la detección de posibles eventos de riesgo revela una tasa de éxito de 94.22%, con un intervalo de confianza de 95% que abarca del 90% al 94.99%. Dado que el valor del 93% se encuentra dentro de este intervalo y el valor p es 0.9981, no se dispone de evidencia suficiente para rechazar la hipótesis global nula. Esto respalda que el prototipo cumple con el estándar requerido, manteniendo una proporción de éxitos igual o superior al 93% con un 95% de confianza.

En relación con los objetivos específicos planteados, el primero de ellos (Caso 1) tiene como fin estimar la tasa general de éxito del prototipo utilizando el equipo Lenovo Ideapad en tres niveles de riesgo y ambos sistemas de advertencia, con una meta mínima de 93%. El análisis indicó que la tasa general de éxito en la detección de riesgos de colisión frontal y punto ciego fue de 94.44%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 95.22%. Dado que el 93% se encuentra dentro de este intervalo y el valor p es 0.9975, se concluye que no hay suficiente evidencia para rechazar la hipótesis nula $H_0: p \geq 0.93$ relacionada con este objetivo, confirmando que el prototipo cumple con el estándar requerido. Cabe destacar que para la determinación del número de ensayos n (2250 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.000412%, lo que implica que la Potencia de la muestra es de 99.9588%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%.

El segundo objetivo específico (Caso 2) se centra en la estimación de la tasa de éxito del prototipo utilizando el equipo LattePanda Delta 3 para la detección de eventos de los sistemas de advertencia de punto ciego y colisión frontal, también con un objetivo mínimo de 93%. El análisis mostró una tasa de éxito de 93.89%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 95.29%. Nuevamente, el 93% se encuentra dentro de este intervalo, y el valor p es 0.8435, lo que lleva a la conclusión de que no hay suficiente evidencia para rechazar la hipótesis nula $H_0: p \geq 0.93$ en este contexto, lo que refuerza que el prototipo cumple con el estándar requerido. Cabe destacar que para la determinación del número de ensayos n (720 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.09951%, lo que implica que la Potencia de la muestra es de 90.0490%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%.

El tercer objetivo específico (Caso 3) se enfocó en la detección de colisiones frontales en las tres zonas de riesgo utilizando el equipo Lenovo Ideapad, con la misma meta mínima del 93%. El análisis reveló una tasa de éxito del 95.33%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 96.53%. Dado que el 93% se encuentra dentro de este intervalo y el valor p es 0.9967, se concluye que el prototipo cumple con el estándar requerido, al igual que en los casos anteriores. Cabe destacar que para la determinación del número de ensayos n (1500 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.00668%, lo que implica que la Potencia de la muestra es de 99.3320%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%.

El cuarto objetivo específico (Caso 4), enfocado en la detección de puntos ciegos en las tres zonas de riesgo utilizando el equipo Lenovo Ideapad, también mostró resultados favorables, con una tasa de éxito de 94% y dentro de un intervalo de confianza de 95% con

límite inferior de 90% y límite superior de 94.98%. El 93% se encuentra dentro de este intervalo, y el valor p es 0.9443, confirmando que no hay suficiente evidencia para rechazar la hipótesis nula $H_0: p \geq 0.93$ en este caso. Cabe destacar que para la determinación del número de ensayos n (750 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.046923%, lo que implica que la Potencia de la muestra es de 95.3077%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%

El quinto objetivo específico (Caso 5) se dirigió a la detección de colisiones frontales en las tres zonas de riesgo utilizando el equipo LattePanda Delta 3, con un objetivo de 93%. El análisis mostró una tasa de éxito de 95.83%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 97.72%. El 93% se encuentra dentro de este intervalo, y el valor p es 0.975, lo que sugiere que el prototipo cumple con el estándar requerido. Cabe destacar que para la determinación del número de ensayos n (480 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.090269%, lo que implica que la Potencia de la muestra es de 90.9731%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%.

Finalmente, el sexto objetivo específico (Caso 6) se centró en la detección de puntos ciegos en las tres zonas de riesgo utilizando el equipo LattePanda Delta 3, también con un objetivo mínimo de 93%. El análisis reveló una tasa de éxito de 93.18%, dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 97.72%. Con un valor p de 0.975, se concluye que no hay suficiente evidencia para rechazar la hipótesis nula $H_0: p \geq 0.93$, confirmando una vez más que el prototipo cumple con el estándar requerido. Cabe destacar que para la determinación del número de ensayos n (240 pruebas), se estableció como valor de probabilidad de cometer el Error tipo II (β) el 0.099935%, lo que implica que la

Potencia de la muestra es de 90.0065%. Esto para asegurar que el no rechazo de H_0 sea una conclusión fuerte. Adicionalmente, se fijó como diferencia mínima a detectar el 3%

El análisis estadístico exhaustivo realizado sobre el prototipo demuestra de manera consistente que este cumple con los estándares requeridos, manteniendo una tasa de éxito igual o superior al 93% en la detección de eventos de colisión frontal y punto ciego, con un alto grado de confianza.

Los resultados obtenidos a partir de múltiples pruebas, que abarcan distintos niveles de riesgo (bajo, medio y alto) y el uso de diferentes dispositivos (Lenovo Ideapad y LattePanda Delta 3), indican que los prototipos presentan una tasa de éxito promedio que varía entre 93.18% y 95.83%. Estos valores se encuentran dentro de un intervalo de confianza de 95% con límite inferior de 90% y límite superior de 97.72%, lo que refuerza la fiabilidad de los resultados obtenidos.

En cada uno de los objetivos específicos evaluados, los valores p obtenidos (los cuales varían desde 0.8435 hasta 0.9981) son significativamente superiores al umbral de significancia de 0.05. Esto implica que no existe suficiente evidencia estadística para rechazar las hipótesis nulas planteadas en relación con las tasas de éxito del prototipo en las diferentes configuraciones y escenarios evaluados.

Por lo tanto, se concluye que el prototipo no solo alcanza, sino que supera de manera consistente el estándar mínimo de 93% de éxito en la detección de eventos de riesgo, tanto en condiciones de colisión frontal como en la identificación de puntos ciegos. La solidez de estos resultados respalda la eficacia del sistema, garantizando un desempeño confiable en la prevención de posibles eventos de riesgo, lo que lo hace apto para su implementación en escenarios reales.

Las pruebas de campo permitieron reconocer los aspectos relevantes en cuanto a las implicaciones existentes alrededor de la detección de vehículos en tiempo real desde un hardware limitado para el procesamiento continuo y eficaz.

Al comparar los prototipos (Lenovo Ideapad y LattePanda Delta 3) en el contexto del posprocesamiento de captura y procesamiento de video en tiempo real, se concluye que el prototipo Lenovo Ideapad demuestra un rendimiento superior en los aspectos evaluados.

Primero, en cuanto a los tiempos de detección, el prototipo (Lenovo Ideapad) registró un tiempo promedio de 0.3640 segundos, superando claramente al prototipo (LattePanda Delta 3), cuyo tiempo promedio fue de 0.6331 segundos. La diferencia promedio de 0.2691 segundos señala que el prototipo (Lenovo Ideapad) es un 44% más rápido en la detección, lo cual es crucial para la presente aplicación que requiere procesamiento en tiempo real.

En términos de consistencia y variabilidad en los tiempos de detección, el prototipo (Lenovo Ideapad) también mostró una clara ventaja. La desviación estándar y la varianza de sus tiempos de detección fueron significativamente menores (0.0722 y 0.0052, respectivamente) en comparación con el prototipo (LattePanda Delta 3) (0.1901 y 0.0362, respectivamente). Estos resultados indican que el prototipo (Lenovo Ideapad) no solo es más rápido, sino también más predecible y consistente en su rendimiento.

El uso de memoria RAM fue otro factor crucial en la comparación. El prototipo (Lenovo Ideapad) utilizó un promedio del 51% de su memoria RAM durante las operaciones, mientras que el prototipo (LattePanda Delta 3) utilizó un promedio del 62%. Este mayor consumo de RAM en el prototipo (LattePanda Delta 3) sugiere una gestión de recursos menos eficiente, lo cual podría estar contribuyendo a sus mayores tiempos de detección.

En cuanto al rendimiento térmico y uso de CPU, el prototipo (Lenovo Ideapad) también demostró ser más eficiente. Operando a una temperatura promedio de 73°C y utilizando el 64% de su capacidad de CPU, el prototipo (Lenovo Ideapad) logró un balance adecuado entre

rendimiento y gestión térmica. Por otro lado, el prototipo (LattePanda Delta 3) operó a una temperatura promedio de 83°C, utilizando el 97% de su capacidad de CPU, lo que no solo resultó en mayores tiempos de detección, sino que también podría reducir la vida útil del dispositivo debido al estrés térmico constante.

Es importante destacar las implicaciones del hardware en el rendimiento de ambos dispositivos. El prototipo (Lenovo Ideapad), equipado con un procesador AMD Ryzen 7 4800H y gráficos Radeon integrados, cuenta con una arquitectura y capacidad de procesamiento más avanzada, permitiendo un rendimiento superior. En contraste, el prototipo (LattePanda Delta 3), con un procesador Intel Celeron N5 105, presenta limitaciones significativas que afectan negativamente su capacidad para manejar tareas de procesamiento intensivo.

El desarrollo e implementación de este sistema de alerta y monitoreo de conducción destaca el potencial para avances significativos en la tecnología de seguridad vehicular. Al integrar el aprendizaje automático y el procesamiento de datos en tiempo real, el sistema ofrece una solución para mejorar la conciencia y la respuesta del conductor ante posibles peligros. Esta innovación no solo tiene como objetivo mejorar la seguridad de los vehículos individuales, sino que también contribuye a los esfuerzos más amplios de seguridad vial, reduciendo potencialmente el número total de incidentes y fatalidades en el tráfico.

En el análisis de precios entre el Prototipo 1, que utiliza el equipo Lenovo Ideapad, y el Prototipo 2, que emplea el equipo LattePanda Delta 3, es relevante destacar que la diferencia en la tasa de éxito entre ambos dispositivos es mínima. Esto indica que el Prototipo 2 podría proporcionar un rendimiento adecuado a un costo significativamente menor. El Prototipo 2, con un costo de \$300 USD, representa una opción económica y competitiva para un sistema de ADAS, especialmente en comparación con el costo de adquirir componentes individuales o kits integrales. Esta característica hace del Prototipo 2 una solución atractiva para quienes buscan reducir costos sin comprometer el rendimiento esencial del sistema de advertencia y

detección de riesgos. La implementación del Prototipo 2 en un vehículo sin sistema ADAS puede resultar en mejoras notables en términos de seguridad, costo, flexibilidad y valor agregado. Es una solución eficiente para actualizar vehículos más antiguos con tecnologías modernas de asistencia al conductor sin requerir una inversión considerable.

VII. TRABAJOS FUTUROS

El alcance de esta tesis cubre una amplia gama de áreas de investigación, como resultado esto conduce a un gran número de campos para la investigación en curso. A continuación, se incluye una breve lista de posibles áreas de trabajo futuro que se pueden llevar a cabo para mejorar las etapas del sistema de reconocimiento.

7.1 Detección de objetos en baja iluminación

Otra área de mejora es la detección de objetos en condiciones de baja iluminación. Comprender los efectos de una mala iluminación en los colores de las imágenes capturadas por las cámaras es un área importante de investigación, no solo para este caso de estudio. Se propone el uso de filtros capaces de generar las imágenes a una escala de grises y realizar la detección mediante bordes o formas, representando otra área de investigación futura.

7.2 Profundidad

Es sustancialmente importante conocer la distancia entre el vehículo objetivo y el vehículo sujeto, si bien es posible conocer la distancia mediante diferentes algoritmos (como se realiza en este caso de estudio) estos infieren un mayor tiempo de procesamiento de cada fotograma capturado. Se propone incluir diferentes sensores como LiDAR para aumentar la eficiencia y disminuir el tiempo de procesamiento directamente en Python.

7.3 Seguimiento de objetos (Radar)

El seguimiento de objetos en tiempo real supondría una mejora en varios aspectos. Esta herramienta ayudaría en diferentes escenarios en ambientes urbanos con una gran cantidad de vehículos a evaluar en instantes de tiempo. En diversos casos de estudios, se ha demostrado que el seguimiento de objetos es una gran herramienta añadida a los sistemas de seguridad avanzados en los vehículos.

VIII. BIBLIOGRAFÍA


- America's Premier Personal Injury & Accident Advocates Law Firm. (2021). *Most Dangerous Car Accidents*. Obtenido de <https://www.theadvocates.com/knowledge-base/montana/top-5-most-dangerous-car-accidents/>
- ASEAN NCAP. (2020). *Test-Protocol-BST-Detection*. Obtenido de Programa de Evaluación de Vehículos Nuevos: https://www.aseancap.org/v2/wp-content/uploads/2020/01/12.-ASEAN-NCAP-MS_Test-Protocol-BST-Detection-Version-1.0_2019-FINAL_1-NOV-2019.pdf
- Asociación Mexicana de La Industria Automotriz. (2020). *Sistemas ADAS en México*. Obtenido de <https://www.amia.com.mx/about/vehiculos-mexico/>
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-y. (s.f.). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. Obtenido de <https://arxiv.org/abs/2004.10934>
- Centro de Experimentación y Seguridad Vial. (17 de Febrero de 2017). *Hacia un nuevo concepto de conducción: conectividad, autonomía y seguridad*. Obtenido de CESVIMAP: <https://www.revistacesvimap.com/hacia-un-nuevo-concepto-de-conduccion-conectividad-autonomia-y-ciberseguridad/>
- Cheung, H., Siu, W., Lee, S., Poon, L., & Ng, C. (2012). Accurate distance estimation using camera orientation compensation technique for vehicle driver assistance system. *IEEE International Conference on Consumer Electronics*, 227-228.
- DECI. (2023). *The history of YOLO object detection models from YOLOv1 to YOLOv8*. Obtenido de Deci AI Documentation Hub: <https://deci.ai/blog/history-yolo-object-detection-models-from-yolov1-yolov8/>
- Fundación MAPFRE. (8 de febrero de 2022). *Ventajas sistemas ADAS*. Obtenido de Fundación MAPFRE: <https://www.fundacionmapfre.org/educacion-divulgacion/seguridad-vial/sistemas-adas/que-son-los-sistemas-adas/ventajas-sistemas-adas/>
- Hines, W. W., & Montgomery, D. C. (1996). *Probabilidad y estadística para ingeniería y administración*. México, D.F.: Compañía Editorial Continental, S.A. de C.V.
- Hoang, M. (2023). *Object size measurement and camera distance evaluation for electronic components using fixed-position camera*. Obtenido de Sanderman Publishing: <https://www.sandermanpub.net/uploads/20230328/38f51297f5272ddfd5dd10855f1166a4.pdf>
- INEGI. (2021). *Estadística de Accidentes de Tránsito Terrestre en Zonas Urbanas y Suburbanas*. Obtenido de <https://www.inegi.org.mx/programas/accidentes/>
- INEGI. (17 de Noviembre de 2022). *Estadísticas a propósito del Día Mundial en Recuerdo de las Víctimas de Accidentes de Tránsito 2022*. Obtenido de Instituto Nacional de Estadística y Geografía: https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2022/EAP_VICACCT22.pdf
- INEGI. (2022). *Vehículos de motor registrados*. Obtenido de Subsistema de Información Económica:

- https://inegi.org.mx/sistemas/olap/proyectos/bd/continuas/transporte/vehiculos.asp?s=est&c=13158&proy=vmrc_vehiculos
- Instituto Nacional de Estadística y Geografía (INEGI). (2021). *Características de las defunciones registradas en México durante 2020*. Obtenido de INEGI: https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2021/EstSociodemo/DefuncionesRegistradas2020_Pre_07.pdf
- Instituto Nacional de Estadística y Geografía (INEGI). (2021). *Parque vehicular*. Obtenido de Economía y Sectores Productivos: <https://www.inegi.org.mx/temas/vehiculos/>
- Instituto Nacional de Salud Pública. (2021). *México, séptimo lugar mundial en siniestros viales*. Obtenido de Portal de la Secretaría de Salud Pública: <https://www.insp.mx/avisos/4761-seguridad-vial-accidentes-transito.html>
- Insurance Institute for Highway Safety (IIHS), Global NCAP, Latin NCAP. (2016). *Nissan Finally Take Zero Star Tsuru Out Of Production Following NCAP Campaign*. Obtenido de Latin NCAP: <https://www.latinncap.com/en/media-area/new/858124db759761/nissan-finally-take-zero-star-tsuru-out-of-production-following-ncap-campaign>
- Kexin, L., & Qiang, L. (2022). *Improved edge lightweight YOLOv4 and its application in on-site power system work*. Obtenido de ScienceDirect: <https://www.sciencedirect.com/science/article/pii/S2096511722000342/pdf?md5=9192b02cdf21bb8dfb4bf8f82a41cf1d&pid=1-s2.0-S2>
- KIA. (2018). *Sorento Showroom*. Obtenido de <https://www.kia.com/mx/showroom/sorento.html>
- LATIN NCAP. (2023). *Impacto Frontal y Lateral*. Obtenido de <https://www.latinncap.com/en/our-tests/adult-occupant/>
- MAPFRE. (3 de junio de 2023). *Normativas 2024 coches más seguros incorporan ADAS*. Obtenido de Motor Mundial MAPFRE: <https://www.motor.mapfre.es/consejos-practicos/seguridad-vial/los-coches-mas-seguros-incorporan-adas/>
- MathWorks. (2023). *You Only Look Once version 4 (YOLO v4) object detection network*. Obtenido de Matlab: <https://www.mathworks.com/help/vision/ug/getting-started-with-yolo-v4.html>
- McGill SC. (2022). *Tkinter private and public methods*. From McGill School of Computer Science: <https://www.cs.mcgill.ca/~hv/classes/MS/TkinterPres/#VMETHODS>
- Minitab LLC. (2018). *Minitab Statistical Software (Versión 18.1)*. Obtenido de <https://www.minitab.com>
- National Highway Traffic Safety Administration (NHTSA). (2022). *Tecnologías de asistencia al conductor*. Obtenido de NHTSA: <https://www.iihs.org/topics/bibliography/ref/2243>
- Open Source Computer Vision Team. (2024). *OpenCV (Versión 4.8.0) documentación*. Obtenido de Open CV: <https://opencv.org/about/>
- Paszke, A., Gross, S., Massa, F., & Lerer, A. (2019). PyTorch: An imperative style, high-performance deep learning library. Estados Unidos de América. Obtenido de ArXiv Org: <https://arxiv.org/abs/1912.01703>

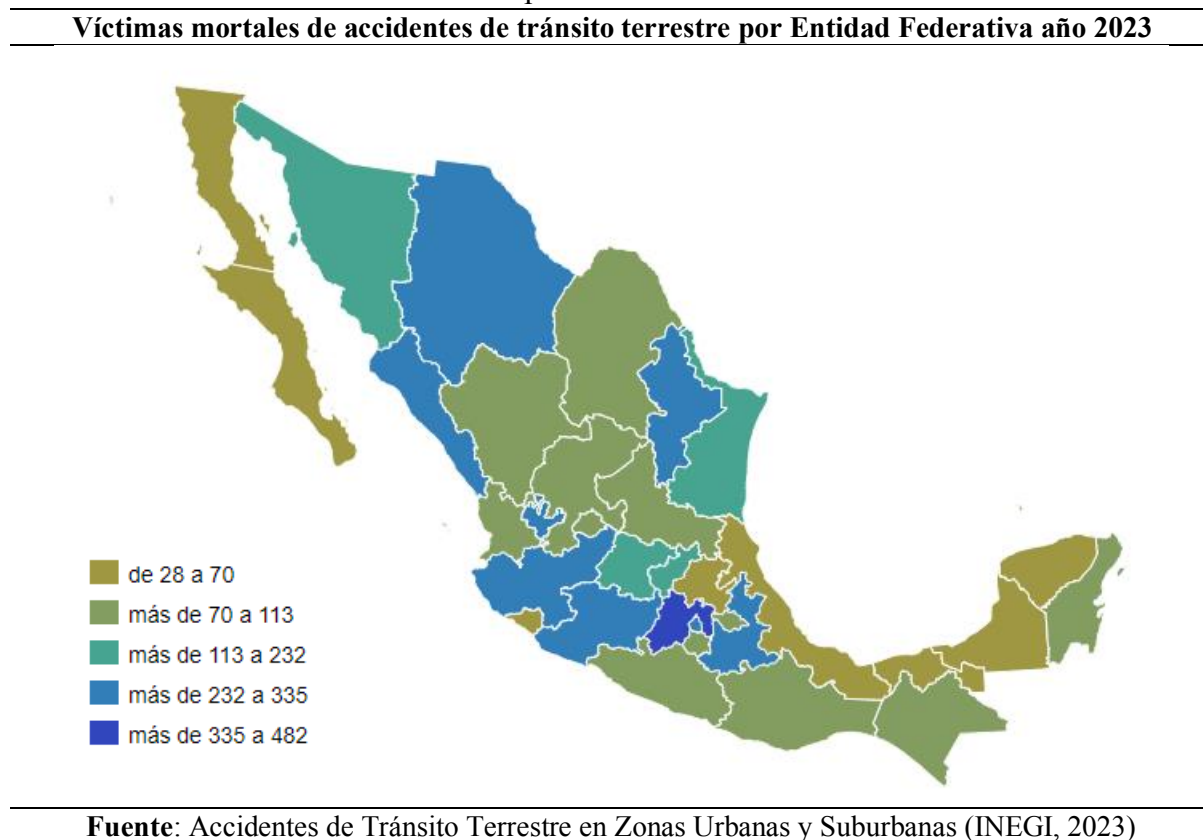
- Periódico El Universal. (2022). *Las 10 marcas de autos más vendidas en México*. Obtenido de El Universal: <https://www.eluniversal.com.mx/autopistas/las-10-marcas-de-autos-mas-vendidas-en-mexico>
- Pygame Org. (2022). *Pygame (Versión 2.1.3) documentación*. Obtenido de https://www.pygame.org/docs/ref/sdl2_controller.html#module-pygame._sdl2.controller
- Python Software Foundation. (2024). *Python (Versión 3.10.5) documentación*. Obtenido de <https://docs.python.org/3/license.html>
- PythonWare. (2023). *Python Imaging Library (Versión 1.1.7) documentación*. From Python Pillow Org: <https://pillow.readthedocs.io/en/stable/>
- PyTorch Team. (2023). *Training with PyTorch*. From <https://pytorch.org/tutorials/beginner/introyt/trainingyt.html>
- Redmon, J., & Farhadi, A. (2020). *You Only Look Once: Unified, real-time object detection*. Obtenido de Science Direct: https://pjreddie.com/media/files/papers/yolo_1.pdf
- Secretaría de Gobernación (SEGOB). (2022). *NORMA Oficial Mexicana (NOM-194-SE-2021), Dispositivos de seguridad esenciales en vehículos nuevos-Especificaciones de seguridad*. Obtenido de Diario Oficial de la Federación: https://www.dof.gob.mx/nota_detalle.php?codigo=5666804&fecha=03/10/2022#gsc.tab=0
- Secretariado Técnico del Consejo Nacional para la Prevención de Accidentes. (2020). *Secretaría de Salud*. Obtenido de <https://www.gob.mx/salud/documentos/informe-sobre-la-situacion-de-la-seguridad-vial-mexico-2020?state=published>
- Stevenson, W. J. (2014). *Operations Management: Theory and Practic*. Berkshire: Mc Graw Hill Education.
- Vallet, M. (2001). *Les dispositifs de maintien de la vigilance des conducteurs de voiture. In Le maintien de la vigilance dans les transports*. Obtenido de <https://journals.open.tudelft.nl/ejtir/article/download/3667/3784/9763>

ANEXOS

Anexo 1: Registro de accidente de tránsito a nivel nacional (México).



Anexo 2: Número de víctimas mortales por Entidad Federativa.




Anexo 3: Estimaciones de la eficacia de la seguridad de ADAS realizadas mediante trabajos previos que agregan los beneficios de seguridad de ADAS más avanzados (Wang et al., 2020; Yue et al., 2018).

Tecnología	Estimaciones de la eficacia de la seguridad	
	Yue et al. (2018) (conservative) [%]	Wang et al. (2020) (95% Intervalo de confianza) [%]
ACC (Control de cruceo adaptativo)	—	[5, 14]
AEB (Frenado automático de emergencia)	43	[20, 31]
BSW (Advertencia de punto ciego)	14	[10, 20]
ESC (Control electrónico de estabilidad)	41	[38, 48]
FCW (Advertencia de colisión frontal)	—	[17, 25]
IMA (Asistencia de movimiento en intersecciones)	40	[40, 57]
LCW (Advertencia de cambio de carril)	28	[10, 33]
LDW (Advertencia de salida de carril)	—	[21, 30]
PCAM (Mitigación de colisión con peatones)	59	[36, 42]
FCW + ACC	10	—
FCW + AEB	50	—
FCW (niebla)	35	—
LDW + Advertencia de velocidad en curvas (CSW)	11	—

Fuente: On the road safety benefits of advanced driver assistance systems in different driving contexts (Masello, L., 2022)

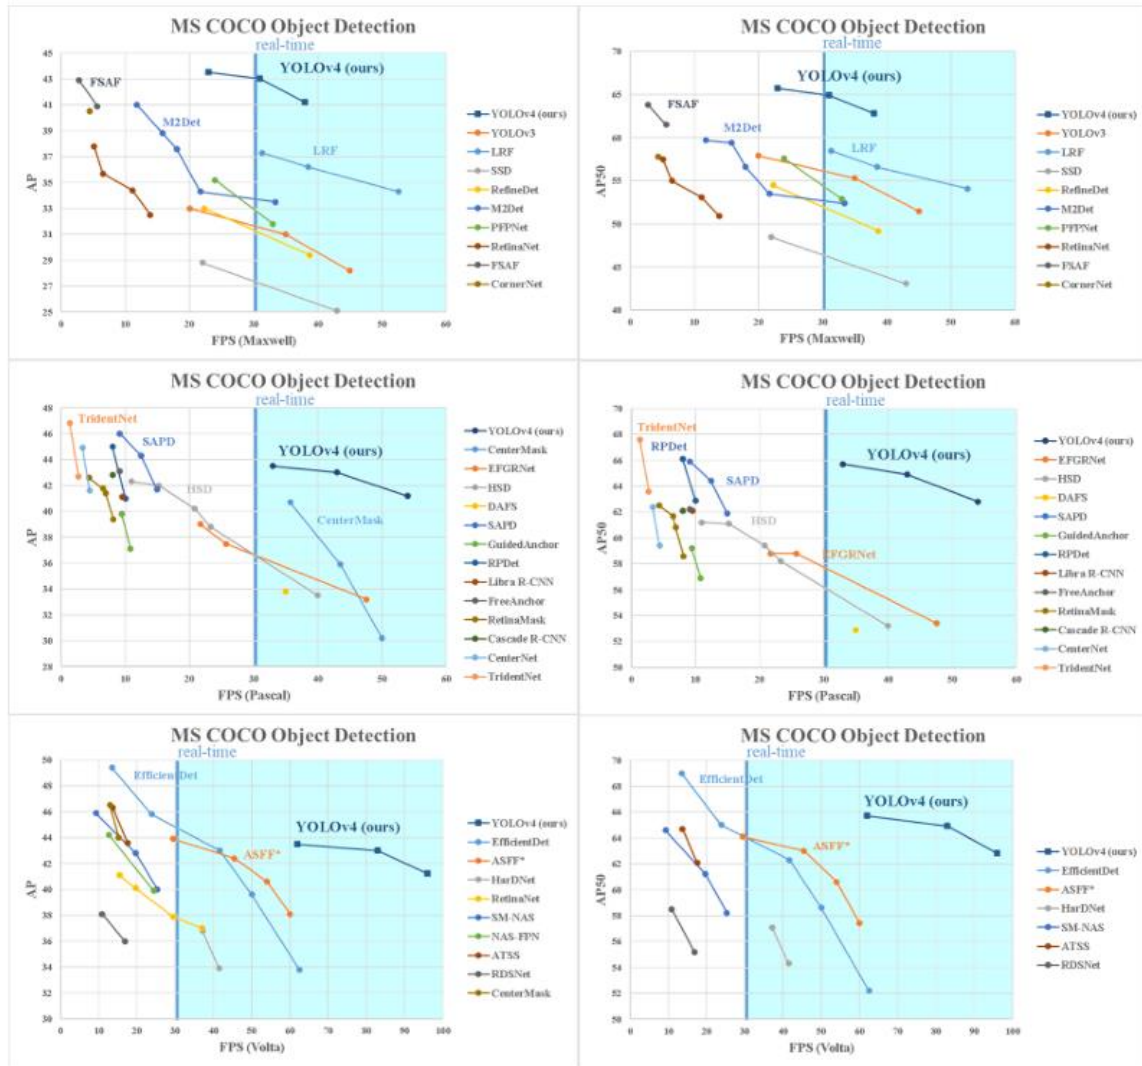
Anexo 4: Proyección de potencial reducción de fatalidades en accidentes terrestres.



Fuente: Análisis del impacto de las ADAS en la seguridad vial: cálculo de los potenciales de reducción (Aleksa, M., 2024)

Anexo 5: Comparación de la velocidad y precisión de diferentes detectores de objetos.

Comparación de la velocidad y precisión de diferentes detectores de objetos en el conjunto de datos MS COCO.



Fuente: YOLOv4: Optimal Speed and Accuracy of Object Detection (Bochkovski, A., 2021)

Anexo 6: Comparación de la velocidad y precisión de diferentes detectores de objetos.

Comparación de la velocidad y precisión de diferentes detectores de objetos en el conjunto de datos MS COCO.

YOLOv3: An incremental improvement [63]									
YOLOv3	Darknet-53	320	45 (M)	28.2%	51.5%	29.7%	11.9%	30.6%	43.4%
YOLOv3	Darknet-53	416	35 (M)	31.0%	55.3%	32.3%	15.2%	33.2%	42.8%
YOLOv3	Darknet-53	608	20 (M)	33.0%	57.9%	34.4%	18.3%	35.4%	41.9%
YOLOv3-SPP	Darknet-53	608	20 (M)	36.2%	60.6%	38.2%	20.6%	37.4%	46.1%
Method	Backbone	Size	FPS	AP	AP ₅₀	AP ₇₅	AP _S	AP _M	AP _L
YOLOv4: Optimal Speed and Accuracy of Object Detection									
YOLOv4	CSPDarknet-53	416	54 (P)	41.2%	62.8%	44.3%	20.4%	44.4%	56.0%
YOLOv4	CSPDarknet-53	512	43 (P)	43.0%	64.9%	46.5%	24.3%	46.1%	55.2%
YOLOv4	CSPDarknet-53	608	33 (P)	43.5%	65.7%	47.3%	26.7%	46.7%	53.3%

Fuente: YOLOv4: Optimal Speed and Accuracy of Object Detection (Bochkovski, A., 2021)